



**ITS**  
Institut  
Teknologi  
Sepuluh Nopember

**TUGAS AKHIR - TE 141599**

# **MANAJEMEN ENERGI SKALA RUMAH TANGGA BERBASIS DYNAMIC PRICING MENGGUNAKAN EXTREME LEARNING MACHINE**

Akhmad Rizki Hidayatullah  
NRP 07111440000105

Dosen Pembimbing

Prof. Dr. Ir. Adi Soeprijanto, MT.  
Rony Seto Wibowo, ST, MT. Dr. Eng

DEPARTEMEN TEKNIK ELEKTRO  
Fakultas Teknologi Elektro  
Institut Teknologi Sepuluh Nopember  
Surabaya 2018

*Halaman ini sengaja dikosongkan*



## **TUGAS AKHIR - TE 141599**

# **MANAJEMEN ENERGI SKALA RUMAH TANGGA BERBASIS DYNAMIC PRICING MENGGUNAKAN EXTREME LEARNING MACHINE**

Akhmad Rizki Hidayatullah  
NRP 07111440000105

Dosen Pembimbing

Prof. Dr. Ir. Adi Soeprijanto, MT.  
Rony Seto Wibowo, ST, MT. Dr. Eng

DEPARTEMEN TEKNIK ELEKTRO  
Fakultas Teknologi Elektro  
Institut Teknologi Sepuluh Nopember  
Surabaya 2018

*Halaman ini sengaja dikosongkan*



**Final Project - TE 141599**

## **HOUSEHOLD ENERGY MANAGEMENT BASED ON DYNAMIC PRICING USING EXTREME LEARNING MACHINE**

Akhmad Rizki Hidayatullah  
NRP 07111440000105

Supervisor

Prof. Dr. Ir. Adi Soeprijanto, MT.  
Rony Seto Wibowo, ST, MT. Dr. Eng

DEPARTEMEN TEKNIK ELEKTRO  
Fakultas Teknologi Elektro  
Institut Teknologi Sepuluh Nopember  
Surabaya 2018

*Halaman ini sengaja dikosongkan*

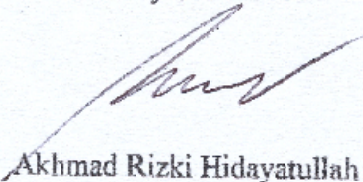
## PERNYATAAN KEASLIAN TUGAS AKHIR

Dengan ini saya menyatakan bahwa isi sebagian maupun keseluruhan Tugas Akhir saya dengan judul "**Manajemen Energi Skala Rumah Tangga Berbasis Dynamic Pricing Menggunakan Extreme Learning Machine**" adalah benar benar hasil karya intelektual mandiri, diselesaikan tanpa menggunakan bahan-bahan yang tidak diijinkan dan bukan merupakan karya pihak lain yang saya akui sebagai karya sendiri.

Semua referensi yang dikutip maupun dirujuk telah ditulis secara lengkap pada daftar pustaka.

Apabila ternyata pernyataan ini tidak benar, saya bersedia menerima sanksi sesuai peraturan yang berlaku.

Surabaya, Mei 2018



Akhmad Rizki Hidayatullah  
0711144000105

*Halaman ini sengaja dikosongkan*



**MANAJEMEN ENERGI SKALA RUMAH TANGGA  
BERBASIS DYNAMIC PRICING MENGGUNAKAN  
EXTREME LEARNING MACHINE**

**TUGAS AKHIR**

**Diajukan Guna Memenuhi Sebagian Persyaratan  
Untuk Memperoleh Gelar Sarjana Teknik  
Pada  
Bidang Studi Teknik Sistem Tenaga  
Departemen Teknik Elektro  
Institut Teknologi Sepuluh Nopember**

**Menyetujui :**

**Dosen Pembimbing I**

**Dosen Pembimbing II**

**Prof. Dr. Ir. Adi Soeprijanto, MT.**  
**NIP. 196404051990021001**

**Rony Seto Wibowo, ST., MT., Dr.Eng.**  
**NIP. 197411292000121001**



*Halaman ini sengaja dikosongkan*

## **Manajemen Energi Skala Rumah Tangga Berbasis Dynamic Pricing Menggunakan Extreme Learning Machine**

Nama Mahasiswa : Akhmad Rizki Hidayatullah  
NRP : 07111440000105  
Dosen Pembimbing I : Prof. Dr. Ir. Adi Soeprijanto, MT.  
NIP : 196404051990021001  
Dosen Pembimbing II : Rony Seto Wibowo, ST, MT, Dr. Eng  
NIP : 197411292000121001

### **ABSTRAK**

Tujuan dari manajemen energi adalah memanfaatkan setiap energi secara efektif dan efisien tanpa mengurangi kualitas energi yang digunakan. Agar terlaksana dengan baik perlu kemampuan pendukung yaitu pencatatan dan evaluasi secara berkala, penjadwalan, serta mampu memberikan saran untuk pemanfaatan energi secara ekonomis. Pada tugas akhir ini manajemen energi diterapkan untuk peralatan skala rumah tangga.

Penjadwalan beban secara efektif dilakukan oleh *smart switch* yang mampu memprediksi harga energi listrik yang akan datang dalam lingkungan yang telah menerapkan *Dynamic Pricing*. Terdapat pengelompokan tipe peralatan rumah tangga berdasarkan energi yang dikonsumsi dan waktu pemakaian peralatan tersebut, yaitu beban inelastis, beban elastis dengan waktu yang fleksibel, beban berjalan dengan waktu yang fleksibel, dan beban elastis dengan daya fleksibel. *Extreme Learning Machine* (ELM) adalah kecerdasan buatan yang digunakan untuk memprediksi harga listrik yang akan datang. Penggolongan tipe peralatan rumah tangga, prediksi harga, dan penjadwalan yang dilakukan oleh ELM, dapat membantu pengguna untuk mengetahui biaya pemakaian energi listrik dan waktu yang tepat untuk menggunakan peralatan listrik secara efektif dan ekonomis sehingga pengguna dapat mengurangi tagihan listrik yang dibayarkan kepada penyedia layanan kelistrikan.

**Kata Kunci** : Manajemen Energi, *Dynamic Pricing*, *Extreme Learning Machine*, Penjadwalan Beban

*Halaman ini sengaja dikosongkan*

## **Household Energy Management Based on Dynamic Pricing using Extreme Learning Machine**

Name : Akhmad Rizki Hidayatullah  
NRP : 07111440000105  
Supervisor I : Prof. Dr. Ir. Adi Soeprijanto, MT.  
NIP : 196404051990021001  
Supervisor II : Rony Seto Wibowo, ST, MT, Dr. Eng  
NIP : 197411292000121001

### **ABSCTRACT**

The purpose of energy management system is managing the energy usage effectively and efficiently without reducing the quality of energy used. To maintain the system works well, the system should be equipped with periodical data record and evaluation, scheduling, and report for economical utilization suggestion of energy usage. In this final report, The energy management system is applied to household appliances.

Load scheduling is effectively performed by the smart switch which able to predict future electricity energy pricing in Dynamic Pricing environments. The household appliances are grouped into several types based on the energy consumed and used time of equipment, such as inelastic load, elastic load in flexible time, continuous load in flexible time, and elastic load in flexible power. Extreme Learning Machine (ELM) is an artificial intelligence used for predict future electricity pricing. The classification of household appliances, price prediction, and scheduling performed in ELM could help the user to monitor the electricity energy cost and manage the electricity equipment usage time so the user can reduce electricity cost paid to the electricity service provider.

**Keywords :** Dynamic Pricing, Energy Management, Extreme Learning Machine, Load Scheduling.

*Halaman ini sengaja dikosongkan*

## KATA PENGANTAR

Puji Syukur penulis panjatkan kehadiran Allah SWT atas segala Rahmat, Karunia, dan Petunjuk yang telah dilimpahkan-Nya sehingga penulis mampu menyelesaikan tugas akhir dengan judul **“Manajemen Energi Skala Rumah Tangga Berbasis Dynamic Pricing Menggunakan Extreme Learning Machine”**.

Tugas Akhir ini disusun sebagai salah satu persyaratan untuk menyelesaikan jenjang pendidikan S1 pada Bidang Studi Teknik Sistem Tenaga, Departemen Teknik Elektro, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember. Atas selesainya penyusunan tugas akhir ini, penulis ingin mengucapkan terima kasih kepada :

1. Allah SWT atas limpahan rahmat, karunia dan petunjuk-Nya.
2. Ibu, Ayah dan kakak penulis di rumah yang selalu mendoakan, mendukung dan memberikan semangat kepada penulis baik dalam keadaan senang ataupun susah.
3. Prof. Dr. Ir. Adi Soeprijanto, M.T dan Rony Seto Wibowo, S.T., MT. Dr. Eng. selaku dosen pembimbing yang telah memberikan arahan, bimbingan dan perhatiannya selama proses penyelesaian tugas akhir ini.
4. Bapak Prof. Ontoseno Penangsang, Dr. Dimas Fajar Uman Putra dan Dr. Ni Ketut Aryani, beserta teman-teman asisten, trainee dan calon trainee serta member lab PSSL B103 yang telah menciptakan dan memberikan dukungan, penjelasan, dan juga suasana kondusif dalam menyelesaikan tugas akhir.
5. Bapak Suyanto yang telah memberikan banyak motivasi dan arahan sejak awal pengajuan tugas akhir ini sampai kini selesainya tugas akhir ini.
6. Seluruh asisten Padepokan P (Mila, Sabil, Aden, Amirul, Fikri, Ori) yang telah memberikan dukungan dan bantuan selama menjabat sebagai asisten *Power System Simulation Laboratory* 2017-2018

7. Dien Nisa Aulia, S.KG terkasih yang telah menjadi motivator pribadi penulis untuk meraih setiap mimpi yang dapat dimulai setelah buku ini selesai.
8. Trainee angkatan 2015 dan 2016 yang merupakan sobat perjuangan PSSSL 2015 – 2016.
9. Kepada teman-teman dekat penulis dari grup JA\*\*OK yang telah menjadi kawan dan lawan dalam menjalani perkuliahan selama 4 tahun (Samid, Ndog, Alpin, Simo, Kaymal, Yoga, Sakaw, Jepik, Lekong, Anang, Ujang, Kamal, dan Restu)
10. Seluruh teman-teman e54, terima kasih atas cerita dan perhatiannya selama ini.
11. Seluruh Dosen dan Karyawan Jurusan Teknik Elektro yang telah berjasa selama empat tahun membantu penulis selama kuliah dan telah memberikan banyak ilmu yang bermanfaat.

Semoga tugas akhir ini bermanfaat bagi mahasiswa maupun peneliti. Penulis menyadari bahwa masih banyak kekurangan, untuk itu kritik dan saran diharapkan untuk penyempurnaan tugas akhir ini.

Surabaya, Mei 2018

Penulis



## DAFTAR ISI

HALAMAN JUDUL.....	i
PERNYATAAN KEASLIAN .....	vii
LEMBAR PENGESAHAN.....	ix
ABSTRAK.....	xi
ABSTRACT .....	xiii
KATA PENGANTAR .....	xv
DAFTAR ISI.....	xvii
DAFTAR GAMBAR .....	xix
DAFTAR TABEL.....	xxi
BAB I.....	1
PENDAHULUAN .....	1
1.1    Latar Belakang.....	1
1.2    Permasalahan .....	2
1.3    Tujuan.....	3
1.4    Batasan.....	3
1.5    Metodologi .....	4
1.6    Sistematika Penulisan .....	5
1.7    Relevansi .....	6
BAB II.....	7
MANAJEMEN ENERGI SKALA RUMAH TANGGA BERBASIS DYNAMIC PRICING .....	7
2.1    Manajemen Energi.....	7
2.2    Pemodelan Peralatan Listrik Rumah Tangga .....	7
2.3 <i>Dynamic Pricing</i> .....	10
2.4    Prediksi .....	13
2.5    Model Artificial Neural Network.....	14
2.6 <i>Extreme Learning Machine</i> .....	18
2.7    Mengukur Kinerja ELM .....	22
2.8    Prediksi Harga Energi Listrik .....	23
2.9    Penjadwalan Beban Listrik Rumah Tangga .....	24
BAB III.....	27
Peramalan Harga Listrik Menggunakan <i>Extreme Learning Machine</i> untuk Menentukan Penjadwalan Pemakaian Peralatan Listrik Skala Rumah Tangga .....	27

3.1	Diagram Alir Metode Prediksi Harga dan Penjadwalan Beban menggunakan ELM .....	27
3.2	Penjelasan Diagram Alir Metode Prediksi Harga menggunakan ELM dan Penjadwalan Beban .....	28
3.3	Membandingkan Hasil Peramalan ELM dengan ANN .....	35
BAB IV .....		37
SIMULASI HASIL DAN PEMBAHASAN .....		37
4.1	Pengumpulan data .....	37
4.2	Analisis Data dan Pembahasan.....	37
BAB V .....		83
PENUTUP .....		83
5.1	Kesimpulan .....	83
5.2	Saran .....	84
DAFTAR PUSTAKA .....		85
LAMPIRAN .....		89
Lampiran 1. Trial and Error hari Senin (\$).....		89
Lampiran 2. MSE, MAPE, Time.....		91
Lampiran 3. Trial and Error hari Rabu (\$) .....		94
Lampiran 4. MSE, MAPE, Time.....		96
Lampiran 5. Trial and Error hari Jumat (\$) .....		99
Lampiran 6. MSE, MAPE, Time.....		101
Lampiran 7. Trial and Error hari Minggu (\$) .....		104
Lampiran 8. Sebagian Data Aktual Hari Senin .....		107
Lampiran 9. Sebagian Data Aktual Hari Selasa .....		109
Lampiran 10. Sebagian Data Aktual Hari Rabu .....		111
Lampiran 11. Sebagian Data Aktual Hari Kamis .....		113
Lampiran 12. Sebagian Data Aktual Hari Jumat .....		115
Lampiran 13. Sebagian Data Aktual Hari Sabtu .....		117
Lampiran 14. Sebagian Data Aktual Hari Minggu.....		119
RIWAYAT HIDUP .....		121

## DAFTAR GAMBAR

Gambar 2.1 Grafik Inclining Block Rates .....	11
Gambar 2.2 Grafik Real-Time Pricing .....	12
Gambar 2.3 Grafik kombinasi antara RTP dengan IBR .....	13
Gambar 2.4 Susunan Artificial Neural Network .....	14
Gambar 2.5 Aktivasi Logsig.....	17
Gambar 2.6 Aktivasi Tansig.....	17
Gambar 2.7 Aktivasi Purelin .....	18
Gambar 2.8 Struktur ELM.....	20
Gambar 2.9 Grafik RTP Rata-Rata Setiap Tahun .....	24
Gambar 3.1 Diagram alir skema penelitian. ....	27
Gambar 3.2 Grafik RTP rata-rata setiap bulan .....	28
Gambar 3.3 Grafik RTP Rata-Rata Setiap Hari.....	29
Gambar 3.4 Korelasi hari Senin dengan Minggu Sebelumnya.....	30
Gambar 3.5 Penggunaan Peralatan Listrik berdasarkan Kebiasaan Konsumen Indonesia .....	34
Gambar 3.6 Penggunaan Peralatan Listrik Setelah Terjadwal.....	35
Gambar 4.1 Grafik perbandingan data histori dan data training ELM hari Senin ('logsig', 15 <i>hidden neuron</i> ).....	40
Gambar 4.2 Grafik perbandingan data aktual, data ramalan ELM dan ANN untuk harga hari Senin, 18 Desember 2017. ....	43
Gambar 4.3 Grafik perbandingan data histori dan data training ELM hari Senin ('logsig', 15 <i>hidden neuron</i> ).....	45
Gambar 4.4 Grafik perbandingan data aktual, data ramalan ELM dan ANN untuk harga hari Selasa, 8 Agustus 2017. ....	48
Gambar 4.5 Grafik perbandingan data histori dan data training ELM hari Rabu ('logsig', 15 <i>hidden neuron</i> ). ....	51
Gambar 4.6 Grafik perbandingan data aktual, data ramalan ELM dan ANN untuk harga hari Rabu, 9 Agustus 2017. ....	53
Gambar 4.7 Grafik perbandingan data histori dan data training ELM hari Kamis ('logsig', 15 <i>hidden neuron</i> ). ....	56
Gambar 4.8 Grafik perbandingan data aktual, data ramalan ELM dan ANN untuk harga hari Kamis, 29 Juni 2017. ....	58
Gambar 4.9 Grafik perbandingan data histori dan data training ELM hari Jumat ('logsig', 15 <i>hidden neuron</i> ). ....	61

Gambar 4.10 Grafik perbandingan data aktual, data ramalan ELM dan ANN untuk harga hari Jumat, 30 Juni 2017. ....	64
Gambar 4.11 Grafik perbandingan data histori dan data training ELM hari Sabtu ('logsig', 15 <i>hidden neuron</i> ). ....	66
Gambar 4.12 Grafik perbandingan data aktual, data ramalan ELM dan ANN untuk harga hari Sabtu, 1 Juli 2017.....	69
Gambar 4.13 Grafik perbandingan data histori dan data training ELM hari Minggu ('logsig', 15 <i>hidden neuron</i> ). ....	71
Gambar 4.14 Grafik perbandingan data aktual, data ramalan ELM dan ANN untuk harga hari Minggu, 26 November 2017 .....	74
Gambar 4.15 Grafik Perbandingan Profil Peralatan Terjadwal. ....	78
Gambar 4.16 Grafik Perbandingan Profil Peralatan Terjadwal .....	79
Gambar 4.17 Grafik Perbandingan Profil Peralatan Terjadwal .....	80
Gambar 4.18 Grafik Perbandingan Total Tagihan Energi Listrik. ..	81

## DAFTAR TABEL

Tabel 2.1 Kelompok Beban Inelastis.....	8
Tabel 2.2 Kelompok Beban Elastis dengan Waktu yang Fleksibel ...	9
Tabel 2.3 Kelompok Beban Elastis Berjalan Terus dengan Waktu yang Fleksibel.....	9
Tabel 2.4 Kelompok Beban Elastis dengan Daya dan Waktu Fleksibel .....	9
Tabel 4.1 Hasil Training ELM hari Senin dengan fungsi aktivasi Logsig.....	39
Tabel 4.2 Perbandingan parameter keakuratan metode ELM dan ANN.....	41
Tabel 4.3 Perbandingan data aktual dan data peramalan pada hari Senin.....	42
Tabel 4.4 Hasil Training ELM hari Selasa dengan fungsi aktivasi Logsig.....	44
Tabel 4.5 Perbandingan parameter keakuratan metode ELM dan ANN.....	46
Tabel 4.6 Perbandingan data aktual dan data peramalan pada hari Selasa.....	47
Tabel 4.7 Hasil Training ELM hari Rabu dengan fungsi aktivasi Logsig.....	49
Tabel 4.8 Perbandingan parameter keakuratan metode ELM dan ANN.....	51
Tabel 4.9 Perbandingan data aktual dan data peramalan pada hari Rabu.....	52
Tabel 4.10 Hasil Training ELM hari Kamis dengan fungsi aktivasi Logsig.....	54
Tabel 4.11 Perbandingan parameter keakuratan metode ELM dan ANN.....	56
Tabel 4.12 Perbandingan data aktual dan data peramalan pada hari Kamis.....	57
Tabel 4.13 Hasil Training ELM hari Jumat dengan fungsi aktivasi Logsig.....	60
Tabel 4.14 Perbandingan parameter keakuratan metode ELM dan ANN.....	62

Tabel 4.15 Perbandingan data aktual dan data peramalan pada hari Jumat. ....	63
Tabel 4.16 Hasil Training ELM hari Sabtu dengan fungsi aktivasi Logsig. ....	65
Tabel 4.17 Perbandingan parameter keakuratan metode ELM dan ANN. ....	67
Tabel 4.18 Perbandingan data aktual dan data peramalan pada hari Sabtu. ....	68
Tabel 4.19 Hasil Training ELM hari Minggu dengan fungsi aktivasi Logsig. ....	70
Tabel 4.20 Perbandingan parameter keakuratan metode ELM dan ANN. ....	72
Tabel 4.21 Perbandingan data aktual dan data peramalan pada hari Minggu. ....	73
Tabel 4.22 Perbandingan Error Peramalan Menggunakan ELM dan ANN. ....	76
Tabel 4.23 Perbandingan training dan testing time ELM dan ANN	77
Tabel 4.24 Perbandingan Manfaat Menggunakan Penjadwalan Beban pada model harga listrik yang berbeda. ....	80

# **BAB I**

## **PENDAHULUAN**

### **1.1 Latar Belakang**

Pengembangan energi yang berkelanjutan semakin digemari oleh berbagai negara yang ada di dunia, sehingga setiap negara berlomba untuk melakukan investasi dalam konsep baru sebuah kota. Tujuan dari investasi tersebut tidak lain adalah untuk memberikan kesejahteraan kepada masyarakat dengan berbagai fasilitas yang ada didalam konsep baru kota tersebut. Inti dari pada konsep baru sebuah kota tersebut ada pada teknologi yang diimplementasikan, berfungsi untuk mendukung setiap kegiatan masyarakat dan juga mengatur pemakaian energi. Konsep ini disebut *smart city*. Parameter dari kepandaian adalah kemampuan untuk menyerap informasi dari sekitar dengan bantuan teknologi komunikasi dan informasi yang ada, sehingga informasi tersebut dapat digabungkan untuk meningkatkan pelayanan pada masyarakat. Konsep *smart city*, tentunya harus terdapat sarana energi yang juga pandai. Pada sistem kelistrikan *smart city*, berbagai inovasi telah diimplementasikan untuk meningkatkan efisiensi dan produksi energi listrik. Sistem kelistrikan ini bernama smart grid. Pertukaran informasi secara *real-time* melalui jaringan komunikasi, sehingga konsumen dapat melakukan penjadwalan pengaktifan peralatan listrik berdasarkan perubahan harga yang diberitahu oleh manajemen energi secara otomatis yang terpasang pada rumah adalah kemampuan dari *smart grid* yang dapat mengatasi masalah keberlanjutan dan keandalan dari sisi konsumen rumah tangga yang disebut *demand response* (DR) [1]. *Smart home* merupakan sebutan untuk rumah yang terdapat pada *smart city*, memiliki kemampuan berkomunikasi dengan pemilik rumah, maupun antar rumah menggunakan jalur komunikasi untuk mengatur dan menginformasikan segala keadaan yang terjadi dirumah salah satunya adalah pemakaian energi listrik [2]. Sistem ini dapat membantu menjadwalkan pemakaian peralatan kelistrikan berdasarkan harga yang akan dibebankan dari pemakaian energi listrik dan juga memberikan pemilik rumah kemampuan untuk mengamati dan mengendalikan dari jarak jauh setiap peralatan yang ada dirumah

tangga berdasarkan keputusan kinerja peralatan itu sendiri karena beberapa peralatan terdapat perbedaan hierarki dan cara kerjanya seperti kulkas dengan mesin cuci. *Smart grid* yang memiliki kemampuan berkomunikasi antara konsumen dengan penyedia layanan listrik [3], dapat memberikan informasi kepada konsumen mengenai harga energi listrik yang sedang berlaku. Konsumsi energi listrik memiliki 3 fase, yaitu beban puncak, beban menengah, dan beban rendah. Untuk pemakaian beban listrik secara bersamaan di satu waktu akan memicu kondisi dimana pemakaian energi listrik di fase beban puncak. Biasanya pada skala rumah tangga akan lebih banyak mengkonsumsi energi listrik dibeban puncak, sehingga pemakaian berlebih pada saat beban puncak dapat menyebabkan efek yang merugikan pada stabilitas dan keandalan dalam jaringan listrik konvensional. Dengan mengurangi penggunaan energi listrik pada saat beban puncak dapat mengurangi kemungkinan untuk pemadaman pada jaringan distribusi maupun transmisi. Tetapi konsumen tidak mengerti waktu yang tepat dalam mengkonsumsi energi listrik tanpa bantuan manajemen energi secara otomatis. Hal ini mendorong konsumen perlu memiliki penjadwalan pemakaian peralatan listrik berdasarkan demand response dengan memprediksi harga energi listrik yang akan datang. Konsumen akan memiliki manajemen energi listrik secara otomatis yang bertujuan untuk menghemat pengeluaran biaya untuk membayar tagihan listrik. Selain itu, konsumen juga dapat mengendalikan secara jarak jauh pemakaian peralatan listrik bila penjadwalan tidak sesuai dengan kebutuhan sesuai hierarki yang telah diatur oleh konsumen. *Extreme Learning Machine* akan melakukan proses untuk memprediksi harga yang akan datang selanjutnya pengguna dapat menentukan penjadwalan pemakaian peralatan yang lebih akurat setiap saat, sehingga penjadwalan otomatis akan semakin terupdate untuk membantu secara otomatis manajemen energi oleh konsumen.

## **1.2 Permasalahan**

Permasalahan yang akan dibahas pada usulan tugas akhir ini dari latar belakang diatas adalah mencari pemodelan yang tepat untuk dynamic pricing pada jaringan kelisrikan baru dengan berbagai batasan yang



telah ditetapkan sebagai pemodelan, selanjutnya dapat membantu *Extreme Learning Machine* melakukan prediksi harga yang akan datang dari jaringan kelistrikan tersebut. Permasalahan selanjutnya setelah mengetahui harga yang akan datang, pengguna akan melakukan penjadwalan terhadap peralatan listrik yang ada di rumah tangga sehingga dapat mengetahui waktu yang tepat dengan biaya yang hemat untuk mengkonsumsi energi listrik dari kegiatan menggunakan peralatan kelistrikan untuk menghindari pemanfaatan pada saat beban puncak.

### 1.3 Tujuan

Penelitian tugas akhir ini bertujuan untuk:

1. Didapatkan prediksi harga yang akan datang dengan kesalahan minimum.
2. Penjadwalan pemakaian peralatan elektronik skala rumah tangga.
3. Penghematan dalam pemakaian energi listrik skala rumah tangga.

### 1.4 Batasan

Dalam menyelesaikan permasalahan pada tugas akhir ini terdapat batasan yang diperlukan, yaitu:

1. Skema tarif yang berlaku dalam tugas akhir ini *adalah real time pricing* (RTP) dengan *inclining block rates* (IBR) yang telah di terapkan oleh *Amereen Illinois Corporation* untuk RTP dan *British Columbia Hydro Company* untuk IBR.
2. Pengguna energi listrik dibatasi hanya untuk pengguna skala rumah tangga.
3. Data RTP dibatasi selang waktu Januari 2016-Desember 2017.
4. Harga IBR yang digunakan yaitu harga pada tahun 2017.
5. Pengelompokan beban berdasarkan tipe peralatan, dan kebutuhan konsumen
6. Rumah tangga diasumsikan telah memiliki *smart switch* sebagai alat pengatur beban secara otomatis
7. Jumlah peralatan tidak diperkirakan, hanya ada total konsumsi daya dari nama peralatan.

8. Penjadwalan beban hanya berdasarkan harga termurah dari hasil prediksi harga dan pengelompokan beban.
9. Penghematan yang didapatkan merupakan hasil dari prediksi harga dan penjadwalan tanpa ada bantuan renewable energy yang terpasang pada rumah.
10. Total konsumsi listrik dari peralatan sesuai dengan spesifikasi yang ada.
11. Peralatan pada penelitian ini sebatas peralatan yang dipaksa untuk beroperasi secara konstan tanpa ada perubahan konsumsi energi ketika sedang beroperasi.

## 1.5 Metodologi

1. Studi Literatur  
Studi literatur berdasarkan paper, jurnal, maupun buku yang menjelaskan tentang manajemen energi, pemodelan sistem peralatan rumah tangga, pemodelan prediksi harga, dan algoritma *Extreme Learning Machine*.
2. Pemodelan Sistem  
Peralatan rumah tangga yang telah dikelompokkan di modelkan matematis berdasar data yang diperoleh.
3. Perancangan Program  
Program yang terdapat pada tugas akhir ini ada 2 program utama yaitu program untuk memodelkan *dynamic pricing* agar dapat menemukan prediksi harga yang akan datang. Kedua program yang akan digunakan pada tugas akhir ini adalah *Extreme Learning Machine* yang kinerjanya dalam melakukan permalan harga listrik akan dibandingkan dengan *Artificial Neural Network*.
4. Simulasi  
Simulasi dilakukan pada program pertama yang telah dibuat dengan inputan hasil korelasi 3 terbaik dari data yang telah dikelompokkna pada hari yang sama antara hari ini dengan hari pada minggu sebelumnya agar dapat menghasilkan error terkecil dalam melakukan peramalan. Kinerja program pertama akan dibandingkan dengan program kedua yang juga dapat melakukan peramalan harga listrik. Setiap data akan disimulasikan untuk menghasilkan luaran akhir yaitu berupa prediksi harga agar dapat dilakukan penjadwalan peralatan.

5. Implementasi

Dari luaran simulasi, akan dilakukan penjadwalan secara manual sebagai prototype yang nantinya akan digunakan sebagai masukkan kedalam *smart meter* yang telah memiliki fitur peramalan harga yang akan datang dan *smart switch* yang dapat secara otomatis mengontrol nyala matinya suatu peralatan sesuai dengan input yang diberikan pada penelitian selanjutnya

6. Kesimpulan

Dari hasil simulasi dan implementasi dapat di tarik kesimpulan hasil dari penelitian yang telah dijalankan.

7. Penyusunan Laporan

Pembuatan laporan dilakukan setelah seluruh tahap penelitian telah dilaksanakan yang selanjutnya kesimpulan dan hasil dari seluruh tahapan penelitian ditulis dalam laporan.

## 1.6 Sistematika Penulisan

**BAB I**      Pendahuluan.

Pada bab ini dijelaskan mengenai latar belakang permasalahan dari pengerjaan tugas akhir, tujuan, permasalahan, batasan masalah, metodologi penelitian, sistematika penulisan dan relevansi pengerjaan tugas akhir.

**BAB II**      Manajemen Energi, Pemodelan Beban Listrik Rumah Tangga, Dynamic Pricing, Prediksi harga, Artificial Neural Network dan Extreme Learning Machine, serta Penjadwalan Beban Listrik Rumah Tangga. Sebagai obyek kajian pada tugas akhir ini.

**BAB III**      Perancangan dan Pemodelan  
Pada tahap ini akan menjelaskan mengenai penerapan *Extreme Learning Machine* untuk memprediksi harga listrik yang akan dibandingkan dengan *Artificial Neural Network*, penerapan *real time pricing* dan *inclining block rate* pada sistem kelistrikan, pengelompokan peralatan kelistrikan yang terpasang pada rumah, dan penjadwalan

penggunaan peralatan listrik untuk mendapatkan penghematan dalam tagihan listrik.

**BAB IV** Simulasi dan Analisis.  
Pada tahap ini akan dijelaskan setiap langkah dari penelitian yang dilakukan, serta analisis hasil luaran dari simulasi yang menjadi penelitian.

**BAB V** Penutup.  
Pada tahap akhir ini memberikan penjelasan mengenai kesimpulan dan saran dari hasil penelitian pada tugas akhir ini.

## **1.7 Relevansi**

Penelitian diharapkan dapat memberikan manfaat, yaitu:

1. Diperoleh prediksi harga beberapa hari kedepan untuk penjadwalan penggunaan peralatan rumah tangga agar meraih penghematan penggunaan energi listrik.
2. Menjadi masukan yang sesuai untuk pengembangan desain *Smart Switch* yang akan datang.
3. Menjadi referensi bagi mahasiswa yang akan mengerjakan penelitian dengan topik penjadwalan beban, *dynamic pricing*, prediksi harga dan ELM.

## **BAB II**

### **MANAJEMEN ENERGI SKALA RUMAH TANGGA BERBASIS DYNAMIC PRICING**

#### **2.1 Manajemen Energi**

Manajemen energi skala rumah tangga merupakan cara untuk mengatur *demand respond* (DR) dari konsumsi energi listrik yang di gunakan oleh konsumen rumah tangga. Semakin berkembangnya perekonomian suatu keluarga akan meningkatkan konsumsi energi listrik keluarga tersebut. Hal ini dapat merugikan dari kedua pihak baik dari sisi perusahaan yang menyediakan listrik maupun dari sisi konsumen, karena semakin meningkatnya DR suatu keluarga maka perusahaan penghasil energi listrik juga harus menyediakan sarana lebih untuk mengirimkan energi dari pembangkit ke konsumen, hal ini akan menjadi sangat merugikan bila penambahan diluar dari rencana dan akan memperpendek umur dari peralatan yang mengirimkan energi listrik kepada konsumen. Dari sisi konsumen, akan merasakan tagihan yang berlebih bila konsumsi daya listrik tidak diatur sedemikian rupa, sehingga perlunya manajemen energi untuk menjaga agar tagihan listrik yang dibayarkan konsumen kepada perusahaan penyedia energi listrik tidak berlebih dan tetap terjaga umur dari peralatan milik perusahaan penyedia energi listrik sesuai rencana [4].

#### **2.2 Pemodelan Peralatan Listrik Rumah Tangga**

Sistem yang akan diasumsikan didalam usulan tugas akhir ini adalah sistem rumah tangga yang hanya memiliki satu sumber energi listrik dengan berbagai konsumen perumahan. Asumsi selanjutnya adalah setiap perumahan telah memiliki *smart meter* [5], yang terhubung dengan sistem distribusi *smart power* yang dapat berkomunikasi dua-arah melalui jaringan komputer [6-8]. Setiap *smart meter* terdapat *smart switch* yang dapat menjadwalkan pemakaian peralatan rumah tangga sesuai prediksi harga hasil olahan smart meter yang sesuai dengan harga yang dikeluarkan oleh penyedia layanan energi listrik pada sebelumnya. Adanya *smart switch* dalam *smart meter* selain sebagai pengatur peralatan elektronik, nantinya dapat sebagai alat komunikasi antara penyedia layanan energi listrik dengan konsumen

tentang harga energi listrik yang akan terbaru secara berkala dengan selang waktu 1 jam maupun antar konsumen tanpa perlu perangkat jaringan komputer. Skema pasar energi listrik yang di terapkan dalam tugas akhir ini adalah kombinasi antara *Real Time Pricing* (RTP) dengan *Inclining Block Rates* (IBR) yang akan dijelaskan pada sub bab berikutnya.

Peralatan elektronik pada rumah tangga akan digolongkan menjadi beberapa kelompok lagi berdasarkan tipe peralatan elektronik dan juga kebutuhan dari pada konsumen. Pengelompokan peralatan elektronik rumah tangga pada [9] yaitu beban inelastis, beban elastis dengan waktu yang fleksibel, beban berjalan dengan waktu yang fleksibel, dan beban elastis dengan daya yang fleksibel.

### 2.2.1 Beban Inelastis

Beban inelastis adalah beban yang tidak dapat diganggu ketika sedang bekerja, karena beban ini harus terus bekerja. Pada usulan kali ini, konsumsi daya oleh beban inelastis dimodelkan dan ditambahkan dari data historis pemakaian oleh konsumen. *Smart switch* akan berfungsi sebagai pengatur terhadap peralatan tersebut. Peralatan yang digunakan pada simulasi tugas akhir ini dapat dilihat pada tabel 2.1.

**Tabel 2.1** Kelompok Beban Inelastis

Peralatan	Konsumsi Daya (W)	Jumlah Peralatan	Jadwal Penggunaan
Lampu	18	10	Setiap Hari
Kulkas dan Freezer	110	1	Setiap Hari
Rice cooker	400	1	Setiap Hari
Panggang Roti	800	1	Setiap Hari
TV	59	1	Setiap Hari
Pengering Rambut	400	1	Setiap Hari

### 2.2.2 Beban Elastis Dengan Waktu Yang Fleksibel

Beban elastis dengan waktu yang fleksibel adalah beban yang dapat diatur ketika beban berkerja, tipe ini akan dikontrol oleh *smart switch*. Tidak hanya sebagai kontroler tetapi *smart switch* juga akan mendapatkan data daya yang dikonsumsi selama waktu alat tersebut bekerja. Peralatan yang digunakan pada simulasi tugas akhir ini dapat dilihat pada tabel 2.2.

**Tabel 2.2** Kelompok Beban Elastis dengan Waktu yang Fleksibel

Peralatan	Konsumsi Daya (W)	Jumlah Peralatan	Jadwal Penggunaan
PC	217	1	Setiap Hari
AC	750	3	Setiap Hari
Pompa Air	350	1	Setiap Hari

### 2.2.3 Beban Elastis Berjalan Terus Dengan Waktu Yang Fleksibel

Beban berjalan dengan waktu yang fleksibel adalah beban yang memiliki karakteristik khusus untuk waktu kerjanya, dan ketika bekerja tipe beban ini tidak dapat diganggu atau di matikan. Sehingga *smart switch* akan memberikan rekomendasi waktu yang tepat untuk beban ini bekerja. Peralatan yang digunakan pada simulasi tugas akhir ini dapat dilihat pada tabel 2.3.

**Tabel 2.3** Kelompok Beban Elastis Berjalan Terus dengan Waktu yang Fleksibel

Peralatan	Konsumsi Daya (W)	Jumlah Peralatan	Jadwal Penggunaan
Pencuci Piring	510	1	Setiap Hari
Pencuci Pakaian	500	1	Rabu
Penyedot Debu	350	1	Selasa dan Sabtu
Setrika	400	1	Jumat

### 2.2.4 Beban Elastis Dengan Daya Dan Waktu Fleksibel

Beban elastis dengan daya fleksibel merupakan beban yang dapat dijadwalkan waktu bekerjanya dan ketika bekerja beban ini akan mengkonsumsi daya yang sangat besar, tetapi ketika tidak bekerja mengkonsumsi daya yang minimum sebagai daya untuk kerja pada fase standby.

**Tabel 2.4** Kelompok Beban Elastis dengan Daya dan Waktu Fleksibel

Peralatan	Konsumsi Daya (W)	Jumlah Peralatan	Jadwal Penggunaan
Pemanas Air	350	1	Setiap Hari

Pada beban ini, smart switch akan berfungsi memberikan rekomendasi kapan beban ini bekerja dan juga sebagai kontrol. Peralatan yang digunakan pada simulasi tugas akhir ini dapat dilihat pada tabel 2.4.

### 2.3 Dynamic Pricing

*Dynamic Pricing* adalah strategi penetapan harga yang dapat berubah-ubah berdasarkan waktu demand response. Menurut [10], ada berbagai skema penetapan harga berdasarkan waktu *demand response*, seperti penetapan harga secara *time-of-use* (TOU), *peak load pricing* (PLP), *Vickrey-Clarke-Groves* (VCG), *peak-day-rebates* (PDR), *critical peak pricing* (CPP), *flat pricing*, dan *real-time pricing* (RTP). Setiap skema memiliki variasi di dalamnya. Pada usulan tugas akhir ini, model *dynamic pricing* yang akan digunakan adalah *Inclining Block Rate* (IBR) yang akan dikombinasikan dengan *Real-Time Pricing* (RTP).


#### 2.3.1 Inclining Block Rate

IBR yang disimulasikan pada tugas akhir nanti, mengacu pada [11]. *BC Hydro* telah lama menggunakan IBR sebagai strategi penetapan harga jual energi listrik kepada konsumen. Dalam penerapan IBR, harga penggunaan energi listrik akan lebih mahal sesuai banyaknya energi listrik yang dikonsumsi [12]. *Rates* akan menjadi semakin tinggi ketika konsumen menggunakan energi listrik untuk peralatan rumah tangga melebihi *Threshold* pada setiap bulan, hari, maupun jam yang telah disepakati antara penyedia layanan dengan konsumen. Harga energi listrik yang ditetapkan oleh *BC Hydro* sebesar 8,84 sen/kWh hingga 13,26 sen/kWh setiap energi yang digunakan oleh konsumen. Jika konsumen selama 2 bulan menggunakan listrik kurang dari 1350kWh, maka konsumen akan membayar harga pada langkah pertama (8.84 sen/kWh). Jika lebih, maka konsumen harus membayar harga pada langkah kedua (13.26 sen/kWh) untuk kelebihannya. Model matematis IBR yang diimplementasikan oleh *British Columbia Hydro Company* adalah sebagai berikut:

$$\begin{aligned} x^1 &= x^2 = \dots = x^{T-1} = x^T \\ y^1 &= y^2 = \dots = y^{T-1} = y^T \\ \delta^1 &= \delta^2 = \dots = \delta^{T-1} = \delta^T \end{aligned} \tag{1}$$



Harga yang tidak bergantung pada waktu merupakan harga yang diterapkan oleh *BC Hydro*, karena harga mereka berubah berdasarkan tingkat konsumsi energi oleh konsumen. Penerapan IBR akan mendorong konsumen untuk menghemat penggunaan energi listrik dengan mendistribusikan pemakaian peralatan rumah tangga pada hari lain untuk menghindari membayar energi listrik dengan *rates* yang lebih tinggi. Selain itu, IBR juga dapat membantu menyeimbangkan pemakaian energi listrik setiap jam sehingga mengurangi *peak-to-average ratio* (PAR) [13].




**Gambar 2.1** Grafik Inclining Block Rates

### 2.3.2 Real Time Pricing

Telah banyak penelitian yang menghasilkan teori dan simulasi untuk lebih memahami keuntungan secara ekonomi dari penerapan *Real-time pricing* (RTP) [14-18]. RTP diimplementasikan pada sistem bertujuan agar konsumsi pada saat beban puncak berkurang. Terbukti RTP telah menjadi faktor yang paling efektif untuk program DR pada rumah tangga. Disisi lain, pada [19] telah diteliti mengenai dampak penerapan RTP terhadap lingkungan yang dapat mengurangi potensi level emisi dari SO<sub>2</sub>, Nox, dan CO<sub>2</sub> di berbagai wilayah bagian Amerika Serikat dimana mayoritas pembangkit masih menggunakan bahan bakar minyak untuk memenuhi kebutuhan beban puncak. Hal ini karena mekanisme RTP dapat mengirimkan harga penjualan energi

listrik kepada konsumen, sehingga konsumen memiliki keuntungan untuk mengkonsumsi energi listrik disaat harga termurah. RTP yang akan disimulasikan pada tugas akhir nanti akan menggunakan data dari [20]. Untuk model matematis RTP yang telah diimplementasikan oleh Ameren Illinois Corporation di tuliskan sebagai berikut:

$$x^t = y^t, \forall t \in T \quad (2)$$



**Gambar 2.2** Grafik Real-Time Pricing

### 2.3.3 Kombinasi Inclining Block Rate dengan IBR


Berikut adalah model matematis untuk kombinasi antara RTP dengan IBR. Asumsi bila harga yang akan datang telah diketahui oleh konsumen.  $l^t$  adalah total energi yang dikonsumsi oleh konsumen pada setiap  $t$  jam. Sehingga fungsi penerapan harga adalah:

$$\lambda^t(l^t) = \begin{cases} x^t, & \text{jika } 0 \leq l^t \leq \delta^t \\ y^t, & \text{jika } l^t > \delta^t \end{cases} \quad (3)$$

$$x^t, y^t, \delta^t \geq 0$$

Jika IBR dan RTP, faktor yang akan menjadi batasan yaitu waktu dan juga tingkat konsumsi oleh konsumen dapat diperhitungkan menjadi sebuah tagihan. IBR akan secara otomatis menggantikan harga RTP ketika berada pada beban puncak. Sehingga harga pada saat beban puncak menjadi lebih mahal karena IBR telah terkombinasi dengan

RTP. Dapat dilihat pada gambar 2.3, yaitu grafik yang menggambarkan kombinasi antara RTP dengan IBR.



**Gambar 2.3** Grafik kombinasi antara RTP dengan IBR

## 2.4 Prediksi

Secara umum, prediksi atau peramalan merupakan suatu cara yang digunakan untuk memperkirakan kejadian dimasa mendatang. Menurut [21], peramalan terbagi menjadi dua model utama yaitu peramalan kuantitatif dan kualitatif.

Pada model kualitatif, terdapat upaya untuk memasukkan faktor-faktor yang bersifat subjektif didalam model peramalan. Model ini akan sangat bermanfaat ketika data kuantitatif akurat yang akan diramal sulit diperoleh.

Model lain yaitu peramalan kuantitatif berbeda dengan metode kualitatif. Peramalan kuantitatif akan menggunakan data-data yang bersifat kuantitatif yang jauh dari data bersifat subjektif. Tetapi, metode ini dapat digunakan ketika peramalan memenuhi kondisi berikut ini:

1. Tersedia informasi masa lalu
2. Informasi tersebut dapat dikuantitatifkan dalam bentuk data numerik.

3. Dapat diasumsikan bahwa beberapa aspek pola masa lalu akan terus berlanjut di masa mendatang.


Kondisi yang terakhir dikenal sebagai asumsi kesinambungan. Asumsi ini merupakan premis yang mendasari semua metode peramalan kuantitatif, terlepas dari bagaimana canggihnya metode tersebut [21].

Model kausal atau regresi merupakan metode peramalan kuantitatif yang memasukkan dan menguji variabel-variabel yang diduga akan mempengaruhi variabel dependen. Model ini biasanya menggunakan analisis regresi untuk menentukan mana variabel yang signifikan mempengaruhi variabel dependen.

Model *time series* merupakan model yang digunakan untuk memprediksi masa depan dengan menggunakan data historis. Dengan kata lain, model *time series* mencoba melihat apa yang terjadi pada suatu kurun waktu tertentu dan menggunakan data masa lalu untuk memprediksi, model *time series* dapat diklasifikasikan berdasarkan bentuk atau fungsinya yaitu linear dan non linear. Contoh dari model non linear adalah *neural network*.

## 2.5 Model Artificial Neural Network

*Artificial Neural Network* (ANN) bekerja berdasarkan kerja sel syaraf biologis yang secara umum terdiri dari tiga layer yaitu input layer, hidden layer, dan output layer. Setiap layer memiliki fungsi seperti dendrit, soma, dan axon pada sel syaraf biologis. Pada gambar 2.4 adalah contoh sederhana ANN dengan empat input, empat hidden layer, dan dua output.



**Gambar 2.4** Susunan Artificial Neural Network

Setiap input akan berhubungan dengan setiap hidden unit, dan setiap hidden unit berhubungan dengan setiap output unit. Setiap hubungan tersebut memiliki bobot (*weight value*) yang akan bersesuaian dengan nilai masing-masing. Antara input dan hidden layer, serta hidden layer dan output layer akan terdapat processing unit atau processing element pada setiap layernya [22]. *Output* yang dihasilkan pada ANN merupakan fungsi yang kontinu dari input [23], yang secara matematis dapat dituliskan seperti:

$$O = \sigma(\text{net}) \quad (4)$$

$$\text{net} = \sum_{i=0}^n w_i \cdot x_i \quad (5)$$

Dimana  $O$  adalah output dari ANN,  $\sigma$  merupakan fungsi aktivasi atau sigmoid unit, sedangkan  $\text{net}$  adalah sigma dari  $w_i$  bobot (*weight*) dikalikan dengan  $x_i$  yang merupakan input dari jaringan syaraf tiruan. Perlu beberapa hal yang ditentukan terkait dengan model ANN yaitu arsitektur jaringan yang terdiri dari jumlah layer dan jumlah node di setiap layer. Selain itu, perlunya memilih fungsi aktivasi pada hidden dan output nodes, algoritma training, transformasi data atau metode normalisasi, training, dan testing, dan pengukuran kinerja ANN untuk membangun desain arsitektur ANN [22].

### 2.5.1 Arsitektur Artificial Neural Network

ANN tersusun oleh setiap layer yang memiliki *node* dan saling berhubungan satu sama lainnya. Untuk menyusun desain arsitektur ANN hal berikut perlu ditentukan:

1. Jumlah *input nodes*.
2. Jumlah *hidden layer* dan *nodes* pada *hidden layer*.
3. Jumlah *output nodes*.

Jumlah *hidden layer* dan jumlah nodes pada *hidden layer* memiliki pengaruh paling besar terhadap output ANN diantara ketiga hal tersebut. Fungsi nodes pada hidden layer yaitu mendeteksi kejadian, menangkap pola dari suatu data, dan memetakan hubungan *nonlinear* antara input dan output variabel.

Penentuan jumlah nodes pada *hidden layer* dilakukan secara *trial and error* karena setiap permasalahan atau input memiliki karakteristik dan pola yang berbeda-beda. Untuk menghindari kondisi *overfitting*

pada ANN, sebagai acuan, Tang dan fishwick (1993) membatasi jumlah *hidden layer* sebanyak “n”, dimana n merupakan jumlah input *nodes*. Penentuan jumlah *hidden layer*, terdapat beberapa teori yang menyebutkan bahwa ANN dengan *single hidden layer* sudah mampu melakukan approximacy terhadap fungsi nonlinier dengan tingkat kecepatan yang diinginkan. Banyak peneliti juga menuliskan bahwa mereka menggunakan ANN dengan satu *hidden layer* untuk peramalan. Namun ANN dengan *single hidden layer* membutuhkan lebih banyak *hidden nodes* yang sangat tidak diharapkan saat proses training karena memerlukan waktu yang lama.

### 2.5.2 Fungsi Aktivasi


Pada jaringan syaraf biologis terdiri atas beberapa *neuron* yang memiliki hubungan satu samalain. *Neuron* selanjutnya akan mentransformasika informasi yang diterima melalui sambungan keluarannya menuju ke neuron lain pada jaringan syaraf. Hubungan ini dikenal dengan istilah bobot. Informasi akan disimpan dalam suatu nilai tertentu pada bobot tersebut.

Input merupakan informasi yang akan dikirim ke *neuron* dengan bobot kedatangan tertentu, lalu input ini akan diproses oleh suatu fungsi peramalan yang akan menjumlahkan nilai-nilai semua bobot mendatang. Hasil dari penjumlahan semua nilai bobot akan dibandingkan dengan suatu nilai *threshold* tertentu melalui fungsi aktivasi pada setiap neuron. Bila nilai input yang dibandingkan melewati suatu nilai *threshold* tertentu, maka neuron akan secara langsung diaktifkan sebaliknya, jika nilai input yang dibandingkan tidak melewati suatu nilai *threshold*, maka neuron tidak akan diaktifkan. Saat *neuron* diaktifkan, maka output akan dikirimkan melalui bobot-bobot outputnya ke semua *neuron* yang telah berhubungan dengannya. Fungsi aktivasi pada ANN berfungsi untuk menentukan hubungan antara input dan output node pada sebuah network [24]. Fungsi aktivasi tersebut merupakan fungsi transfer yang akan membatasi nilai output ANN pada batas tertentu. Ada banyak fungsi aktivasi yang digunakan, namun fungsi aktivasi yang paling umum digunakan adalah sebagai berikut:

1. Logsig (Sigmoid Biner)

Nilai fungsi Logsig terletak pada range 0-1. Oleh karena itu, fungsi ini akan digunakan paling sering untuk ANN yang memiliki nilai output terletak pada interval 0 hingga 1. Rumus daripada fungsi Logsig adalah sebagai berikut:

$$y = f(x) = \frac{1}{1+e^{-x}} \quad (6)$$




$$a = \text{logsig}(n)$$

**Gambar 2.5** Aktivasi Logsig

2. Tansig (Sigmoid Bipolar)

Fungsi Tansig hampir memiliki kesamaan dengan fungsi Logsig atau fungsi sigmoid biner. Namun, fungsi Tansig memiliki nilai output pada range -1 hingga 1. Rumus daripada fungsi Tansig adalah sebagai berikut:

$$y = f(x) = \frac{2}{1+e^{-x}} - 1 \quad (7)$$




$$a = \text{tansig}(n)$$

**Gambar 2.6** Aktivasi Tansig

3. Purelin

Fungsi Purelin atau pure-linear memiliki nilai output pada interval – (minus tak hingga) hingga + (plus tak hingga). Rumus daripada fungsi Purelin adalah sebagai berikut:

$$y = x \quad (8)$$



$$a = \text{purelin}(n)$$

**Gambar 2.7** Aktivasi Purelin

## 2.6 *Extreme Learning Machine*

### 2.6.1 Pengenalan ELM

*Extreme Learning Machine* (ELM) adalah hasil dari pengembangan metode kecerdasan buatan yang sebelumnya yaitu *Feed-Forward Neural Network* (FFNN). Peneliti mengembangkan FFNN karena dengan semakin berkembangnya zaman dan semakin kompleksnya permasalahan yang membutuhkan proses prediktif yang lebih akurat. Jika dengan FFNN, akan dijumpai beberapa masalah diantaranya adalah lamanya kecepatan proses menuju konvergen, rendahnya efisiensi pembelajaran, dan tidak jelasnya struktur jaringan dari kecerdasan buatan. Dengan ELM tidak hanya memecahkan permasalahan FFNN, tetapi semakin meningkatkan kemampuan untuk berkembangnya teknis kontrol prediksi dari FFNN[25].

Metode ELM pertama kali diperkenalkan oleh Huang (2004). Menurut Huang, FFNN telah banyak digunakan dalam berbagai aplikasi peramalan karena kemampuannya, yaitu:

1. Untuk memperkirakan pemetaan nonlinear (*nonlinear mapping*) yang kompleks secara langsung dari input sample.
2. Untuk memberikan sebuah model dalam *large class* untuk fenomena alami dan buatan yang sulit untuk ditangani menggunakan teknik parametrik klasik.

Secara umum, seluruh parameter pada FFNN perlu diperbaiki dan hal tersebut menyebabkan adanya hubungan antara parameter di layer yang satu dengan yang lain (parameter weight dan bias). Selama beberapa dekade belakangan ini, metode lain telah digunakan pada berbagai macam algoritma training ANN yaitu *gradient descent*



*method*. Namun, metode tersebut sangatlah lambat karena langkah pembelajaran yang tidak pasti dan mudah terjebak pada *local minima*. Selain itu, metode gradient descent membutuhkan banyak iterasi pada pembelajarannya untuk mendapatkan performa pembelajaran yang baik.

ANN juga memiliki kelemahan yang telah disebutkan sebelumnya yaitu kecepatan *learning* yang rendah. Algoritma pembelajaran yang ada saat ini umumnya memiliki kecepatan learning yang jauh lebih lama dari yang diperlukan. Dengan menggunakan metode konvensional yang ada, terkadang dibutuhkan waktu hingga beberapa jam, hari, bahkan lebih lama lagi saat melakukan training ANN. Oleh karena itu, metode pembelajaran ELM dibuat untuk mengatasi kelemahan-kelemahan yang ada dari ANN khususnya dalam rendahnya kecepatan pembelajaran.


Menurut [Huang] ada dua hal yang menyebabkan ANN pada umumnya memiliki kecepatan pembelajaran yang rendah, yaitu:

1. Menggunakan *slow gradient based learning algorithm* untuk melakukan *training neural network*
2. Semua parameter pada jaringan ditentukan secara *iterative* dengan menggunakan metode pembelajaran tersebut.

Untuk pembelajaran yang menggunakan metode *konvensional gradient based learning algorithm* seperti *Backpropagation* (BP), dan variannya *Lavenberg Marquadt* (LM), semua parameter yang ada pada FFNN harus ditentukan secara manual [26]. Parameter itu adalah *input weight* dan *hidden bias* yang saling berhubungan antar layer, sehingga membutuhkan *learning speed* yang lama dan sering terjebak pada *local minima* [26]. Sementara pada ELM parameter seperti *input weight* dan *hidden bias* akan dipilih secara random sehingga ELM memiliki learning speed yang cepat dan mampu menghasilkan *good generalization performance*.

Pada ELM terdapat *Single-Hidden-Layer Feed-Forward Networks* (SLFNs) [27]. Penelitian yang telah dilakukan membuktikan bahwa input weight dan hidden bias bisa dipilih secara random jika fungsi aktivasi pada *hidden layer* ditentukan secara tidak terbatas, setelah input weight dan hidden bias dipilih secara *random*, SLFNs dapat

dipertimbangkan secara sederhana sebagai sebuah sistem linier dan *output weight* (*weight* yang menghubungkan *hidden layer* ke *output layer*) dari SLFNs dapat ditentukan secara analitis melalui operasi *inverse* dari matriks *output hidden layer*. Hal ini lah yang menjadi konsep algoritma tersebut diberi nama ELM yang memiliki kecepatan learning ribuan kali lebih cepat dan memperoleh performa generalisasi yang lebih baik dibandingkan algoritma pembelajaran seperti *Backpropagation* (BP). Gambar 2.8 Adalah struktur ELM.



**Gambar 2.8** Struktur ELM

### 2.6.2 Model Matematis ELM

SLFNs biasa dengan  $m$  adalah jumlah titik input,  $M$  *hidden nodes*, jumlah dari output adalah  $n$ , fungsi aktivasi  $g(x)$ , dan  $b_i$  adalah nilai *threshold* dari  $i_{th}$  *hidden node*. Ketika diasumsikan terdapat  $N$  sampel yang berbeda  $(x_i, t_i)$ , dimana  $x_i = [x_{i1}, x_{i2}, \dots, x_{im}]^T \in R^m$  dan  $t_i = [t_{i1}, t_{i2}, \dots, t_{in}]^T \in R^n$  sehingga SLFNs dengan jumlah  $M$  *hidden node* dan fungsi aktivasi  $g(x)$  dapat dimodelkan matematis sebagai berikut:

$$\sum_{i=1}^M \beta_i g_i(x_j) = \sum_{i=1}^M \beta_i g(\omega_i \cdot x_j + b_i) = o_j, \quad j = 1, 2, \dots, N \quad (9)$$

Dimana  $\omega_i = [\omega_{i1}, \omega_{i2}, \dots, \omega_{im}]^T$  merupakan vektor dari weight yang menghubungkan  $i_{th}$  *hidden node* dan *input node*.  $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{in}]^T$  adalah *weight vector* yang menghubungkan  $i_{th}$  *hidden node* dan *output node*.  $\omega_i \cdot x_j$  merupakan *inner produk* dari  $\omega_i$  dan  $x_j$ .  $o_j = [o_{j1}, o_{j2}, \dots, o_{jn}]^T$  merupakan nilai jaringan luaran.

SFLNs dengan  $M$  hidden nodes dan fungsi aktivasi  $g(x)$  diasumsikan dapat memperkirakan  $N$  buah sample dengan error 0 dapat dinotasikan sebagai berikut:

$$E(S, \beta) = \sum_{j=1}^N \| o_j - t_j \| = 0 \quad \text{sehingga} \quad o_j = t_j \quad (10)$$

Dimana  $S = [\omega_i, b_i, i=1, 2, \dots, M]$  mengandung *output weight* dan *threshold* dari *hidden nodes*. Untuk menemukan  $S, \beta$  yang optimal adalah target luaran dari pelatihan algoritma SFLNs. Jadi *weight network output* dan error terkecil dari nilai sebenarnya adalah  $\min(E(S, \beta))$ . Yang dapat di tulis model matematisnya sebagai berikut:

$$\min E(S, \beta) = \min_{\omega_i, b_i, \beta_i} \| H(\omega_i, \dots, \omega_M, b_i, \dots, b_M, x_i, \dots, x_N) \beta - T \| \quad (11)$$

$H$  adalah lapisan tersembunyi dari matrix luaran neural network,  $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{in}]^T$  adalah *output weight matrix*,  $T$  adalah nilai target matrix dari sampel yang diuji cobakan. Sehingga setiap elemen dimodelkan matematis sebagai berikut:

$$H(\omega_i, \dots, \omega_M, b_i, \dots, b_M, x_i, \dots, x_N) = \begin{bmatrix} g(\omega_1 x_1 + b_1) & \dots & g(\omega_M x_1 + b_M) \\ \vdots & & \vdots \\ g(\omega_1 x_N + b_i) & \dots & g(\omega_M x_N + b_M) \end{bmatrix}^{N \times M} \quad (12)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_M^T \end{bmatrix}, T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix} \quad (13)$$

Proses jaringan pelatihan SFLNs merupakan permasalahan optimasi non-linier, fungsi objektifnya dapat dilihat dipersamaan (7). Ketika fungsi aktivasi dari *hidden node* yang berbeda seluruhnya berjumlah takhingga, maka *input weight* dan *threshold* dari *network hidden layer* dapat ditetapkan secara acak.  $H$  adalah *hidden layer output matrix* pada NN. Kolom  $i_{th}$  dari  $H$  adalah  $i_{th}$  *hidden node output* yang berhubungan dengan input  $x_1, x_2, \dots, x_N$ .  $g(\omega_1 x_1 + b_1)$  menunjukkan output dari *hidden neuron* yang berhubungan dengan input  $\omega_i x_j$ . Pada ELM, *input weight* dan *hidden bias* diperoleh secara *random* tanpa iterasi. Oleh karena itu, *output weight*

dapat ditentukan secara sederhana dari  $H\beta = T$ , dengan solusi *least-square* (LS) sehingga  $\hat{\beta}$  dimodelkan sebagai berikut:

$$\hat{\beta} = H^{-1}T \quad (14)$$

$H^{-1}$  di definisikan sebagai *inverse* dari matrix H atau *Moore-Penrose generalized inverse* matrix H proses pembelajaran jaringan ELM akan selesai ketika  $\hat{\beta}$  telah terpecahkan.

## 2.7 Mengukur Kinerja ELM

Kinerja dari suatu model peramalan yang dilakukan oleh ELM dapat diukur dengan membandingkan hasil ramalan yang diperoleh dengan data yang sebenarnya terjadi. Secara umum, perbandingan dilakukan dengan membandingkan *Mean-Squared Error* (MSE) atau *Mean Absolute Percentage Error* (MAPE). Ketika nilai MSE dan MAPE semakin kecil akan menunjukkan bahwa algoritma pembelajaran tersebut memiliki kemampuan yang baik dalam mengenali pola suatu data yang diolah. MSE akan menampilkan nilai angka hasil perbandingan kuadratik antara hasil peramalan dengan data yang sebenarnya terjadi. Untuk mengukur kinerja dari ELM ini digunakan tiga parameter, yaitu MSE, MAPE, dan training time.

### 2.7.1 MSE (Mean Squared Error)

MSE merupakan salah satu parameter yang sering digunakan untuk mengukur kinerja pada suatu peramalan. MSE dirumuskan dengan

$$MSE = \frac{\sum_{k=0}^{n-1} (Y'_t - Y_{t-k})^2}{n} \quad (15)$$

Dimana  $Y'_t$  merupakan nilai dari prediksi ANN,  $Y_t$  adalah nilai aktual yang terjadi,  $n$  adalah jumlah data yang diproses. Ketika nilai MSE yang dihasilkan semakin mendekati nol, maka kinerja model peramalan akan semakin baik.

### 2.7.2 MAPE (Mean Absolut Percentage Error)

MAPE adalah parameter lain selain MSE yang sering digunakan untuk mengukur kinerja suatu peramalan. MAPE dapat dirumuskan sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_{prediksi} - Y_{target}}{Y_{target}} \right| \cdot 100\% \quad (16)$$

$Y_{prediksi}$  adalah nilai prediksi dari ANN,  $Y_{target}$  adalah nilai aktual yang terjadi,  $n$  adalah jumlah data yang diproses. Seperti MSE, saat nilai MAPE makin mendekati nol maka kinerja hasil peramalan akan semakin baik.


### **2.7.3 Training dan Testing Time**

*Training time* atau yang biasa dikenal dengan *learning speed* merupakan parameter lain yang biasa digunakan untuk mengukur tingkat kinerja dari ANN [24]. Melalui *training time*, kita dapat mengetahui kemampuan ANN atau ELM untuk mengenali pola dari suatu data. Saat nilai training time menjadi semakin kecil, maka hal tersebut akan menunjukkan bahwa metode ANN memiliki kemampuan yang cepat untuk mengenali pola dari suatu data. Pada parameter ini, dapat menggunakan *syntax* yang bermacam-macam, tergantung bahasa pemrograman yang digunakan. Parameter pada ELM, menggunakan perintah CPU time. Saat melakukan proses testing, ANN menggunakan *testing time* untuk mengetahui berapa lama waktu yang diperlukan. Kecepatan *testing time* dapat menunjukkan kemampuan ANN dalam menghasilkan kualitas output. Semakin cepat waktu testing akan semakin baik kemampuan ANN dalam menghasilkan output. Secara umum *testing time* akan lebih kecil dari *training time*.

## **2.8 Prediksi Harga Energi Listrik**

Dalam memprediksi harga energi listrik, secara umum dapat terlihat dari keseimbangan antara ketersediaan energi listrik dan kebutuhan dari para pelanggan. Harga pada pasar energi listrik tidak mudah untuk di prediksi karena banyak hal spesifik yang dapat berpengaruh pada harga energi listrik tiap jamnya.

Beberapa kejadian yang selalu menyebabkan harga listrik mahal adalah saat sore hari, hari yang panas di musim panas, hari yang dingin di musim dingin [28]. Hari kerja maupun hari libur juga dapat berpengaruh dalam perubahan harga energi listrik secara tidak menentu. Data RTP yang dimiliki awalnya dianalisis menggunakan grafik Pada gambar 2.9 dapat dilihat bahwa rata-rata tiap tahun untuk tahun 2016 lebih tinggi daripada nilai rata-rata pada tahun 2017.



**Gambar 2.9** Grafik RTP Rata-Rata Setiap Tahun

Secara umum dapat terlihat pola dari pergerakan grafik mulai dari jam 1 pagi hingga jam 12 malam. Sehingga dari grafik tersebut dapat mendorong untuk mendapatkan pola pada hari-hari biasa. Tetapi, membuat prediksi harga berdasarkan tahun yang sebelumnya, dapat menyebabkan eror yang besar, hal ini karena dapat dipengaruhi oleh faktor lain seperti kenaikan harga minyak, pajak, maupun inflasi.

## 2.9 Penjadwalan Beban Listrik Rumah Tangga

Penjadwalan beban listrik rumah tangga yang tepat agar mendapatkan harga ekonomis ketika sistem telah menerapkan dynamic pricing, perlu diasumsikan terlebih dahulu bahwa pengguna sangat peduli terhadap besarnya tagihan listrik tetapi beberapa pengguna juga peduli pada kenyamanan dalam menggunakan peralatan yang mereka miliki seperti pencuci alat makan dan membersihkan pakaian. Dua asumsi tersebut dapat berbenturan dengan berbagai skenario yang akan diterapkan dalam penjadwalan.

Asumsikan  $\mathcal{A}$  adalah kumpulan peralatan yang ada pada rumah tangga. Untuk setiap peralatan,  $a \in \mathcal{A}$ , sehingga vektor penjadwalan penggunaan energi  $x_a$  sebagai berikut:

$$x_a \triangleq [x_a^1, \dots, x_a^H] \quad (17)$$

Dimana  $H \geq 1$  adalah area dari penjadwalan yang mengindikasikan jumlah jam kedepan yang akan dipertimbangkan dalam mengambil keputusan dalam penjadwalan konsumsi energi. Sebagai contoh  $H = 24$  atau  $H = 48$ . Untuk setiap hari jam yang akan datang  $h \in \mathcal{H} \triangleq \{1, \dots, H\}$ , nilai real skalar  $x_a^h \geq 0$  menunjukkan terdapat hubungan konsumsi energi 1-h yang dijadwalkan untuk peralatan  $a \in \mathcal{A}$ . Disisi lain,  $E_a$  menunjukkan total energi yang dibutuhkan selama peralatan  $a \in \mathcal{A}$  beroperasi. Sebagai contoh, PHEV dapat menempuh jarak sejauh 40 mil jika sebanyak  $E_a = 16$  kWh total energi terpenuhi pada saat mengisi daya baterai [29]. Sebagai contoh lain, pencuci pakaian membutuhkan  $E_a = 3.6$  kWh sekali operasi [30]. Selanjutnya diasumsikan bahwa setiap peralatan  $a \in \mathcal{A}$  telah di pilih  $\alpha_a, \beta_a \in \mathcal{H}$  sebagai awal dan akhir dari interval waktu konsumsi energi untuk masing-masing peralatan  $a$  yang telah terjadwal secara valid. Syarat  $\alpha_a < \beta_a$  akan selalu terpenuhi. Parameter yang telah ditetapkan sebelumnya  $E_a, \alpha_a$ , dan  $\beta_a$  untuk memenuhi energi setiap peralatan  $a \in \mathcal{A}$  dengan interval waktu  $[\alpha_a, \beta_a]$ , akan memenuhi persamaan:

$$\sum_{h=\alpha_a}^{\beta_a} x_a^h = E_a \quad (18)$$

Dengan harapan  $x_a = 0$  untuk setiap  $h < \alpha_a$  dan  $h > \beta_a$  sebagai peralatan yang tidak beroperasi diluar batas waktu  $[\alpha_a, \beta_a]$  untuk peralatan  $a$ .

Setiap peralatan rumah tangga  $a \in \mathcal{A}$  memiliki tingkat daya maksimum yang dinotasikan sebagai  $\gamma_a^{max}$ . Sebagai contoh, PHEV dapat mengisi hingga  $\gamma_a^{max} = 3.3$  kW setiap jamnya [31]. Beberapa peralatan juga memiliki tingkat daya minimum pada kondisi standby sebesar  $\gamma_a^{min}$  untuk setiap peralatan  $a \in \mathcal{A}$ . Batas atas dan bawah daya sebuah peralatan dibutuhkan untuk penentuan vektor dari penjadwalan energi setiap peralatan  $a \in \mathcal{A}$ :

$$\gamma_a^{min} \leq x_a^h \leq \gamma_a^{max}, \forall h \in [\alpha_a, \beta_a] \quad (19)$$

Pada akhirnya telah diketahui bahwa terdapat batasan terhadap energi yang dikonsumsi oleh setiap peralatan pada setiap jamnya. Batasan ini dinotasikan sebagai  $E^{max}$ , yang dapat diatur oleh peralatan agar dapat memenuhi batasan yang ada pada penjadwalan energi:

$$\sum_{a \in \mathcal{A}} x_a^h, \forall h \in \mathcal{H} \quad (20)$$

Sehingga dari persamaan batasan 18-20 dapat menentukan semua pilihan yang tepat untuk vektor penjadwalan konsumsi energi. Dapat didefinisikan set penjadwalan yang layak sebagai  $\mathcal{X}$  untuk setiap kemungkinan vektor penjadwalan konsumsi energi sebagai:

$$\mathcal{X} = \{x \mid \sum_{h=\alpha_a}^{\beta_a} x_a^h = E_a, \forall a \in \mathcal{A}, \quad (21)$$

$$\gamma_a^{min} \leq x_a^h \leq \gamma_a^{max}, \forall h \in [\alpha_a, \beta_a], \quad (22)$$

$$x_a^h = 0, \forall h \in \mathcal{H} \setminus [\alpha_a, \beta_a], \quad (23)$$

$$\sum_{a \in \mathcal{A}} x_a^h \leq E^{max}, h \in \mathcal{H} \quad (24)$$

Dimana  $x \triangleq (x_a, \forall a \in \mathcal{A})$  merupakan vektor variabel dari penjadwalan konsumsi energi untuk seluruh peralatan. Penjadwalan energi  $x$  sesuai jika  $x \in \mathcal{X}$ , sehingga secara jelas pemilihan  $x$  yang tepat tergantung pada harga listrik. Pengguna akan memberi tahu smart meter yang telah terpasang dengan memasukkan data kebutuhannya  $\gamma_a^{min}, \gamma_a^{max}, \alpha_a, \beta_a$ , dan  $E_a$  untuk setiap peralatan  $a \in \mathcal{A}$ . Selanjutnya penjadwal energi dengan pemrediksi harga listrik dari provider akan menentukan pemilihan yang optimal terhadap vektor penjadwalan penggunaan energi  $x$ . Hasil dari penjadwalan konsumsi energi selanjutnya akan diterapkan pada seluruh peralatan rumah tangga dalam bentuk perintah on/off dengan tingkat energi yang spesifik terhadap smart meter dan smart switch yang menggunakan kabel ataupun wireless.

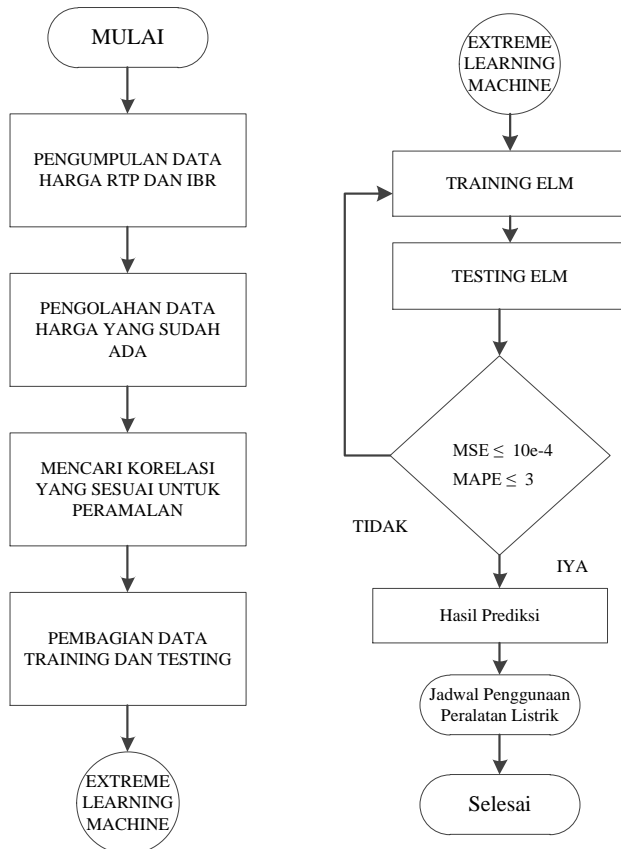
Pada sistem ini, komunikasi wireless menggunakan ZigBee, yang dibuat oleh ZigBee Alliance [32]. Selain ZigBee juga telah ada teknologi komunikasi bernama HomePlug power-line yang dibuat oleh HomePlug Powerline Alliance [33]. Contoh lain teknologi yang sudah ada dapat dilihat pada [34].



### BAB III

## Peramalan Harga Listrik Menggunakan *Extreme Learning Machine* untuk Menentukan Penjadwalan Pemakaian Peralatan Listrik Skala Rumah Tangga

### 3.1 Diagram Alir Metode Prediksi Harga dan Penjadwalan Beban menggunakan ELM



**Gambar 3.1** Diagram alir skema penelitian.

### 3.2 Penjelasan Diagram Alir Metode Prediksi Harga menggunakan ELM dan Penjadwalan Beban

#### 3.2.1 Lokasi Penelitian


Penelitian dilakukan menggunakan skema kelistrikan yang telah diterapkan di negara Amerika dan Inggris. Hal ini karena skema kelistrikan yang sudah ada penelitian pada jurnal maupun paper di IEEE menggunakan data *real time pricing* dan *inclining block rate* yang mengacu pada perusahaan penyedia layanan kelistrikan di negara tersebut bernama *Ameren Illinois* dan *British Columbia Hydro*.

#### 3.2.2 Pengumpulan Data

Data yang digunakan pada penelitian ini adalah data harga *real time pricing* setiap jam yang telah diterapkan oleh *Ameren Illinois* mulai 1 Januari 2016 hingga 31 Desember 2017 dan data *inclining block rate* oleh *British Columbia Hydro* pada tahun 2017.

#### 3.2.3 Pengolahan Data Harga

Data RTP yang telah diperoleh dan diunduh, selanjutnya akan dikelompokkan berdasarkan perhari, yang berisi 24 jam yang selanjutnya akan dikelompokkan perbulan selama 2 tahun. Selanjutnya data juga akan dikelompokkan berdasarkan hari yang sama selama 2 tahun agar dapat dianalisis secara maksimal.




**Gambar 3.2** Grafik RTP rata-rata setiap bulan

Data diolah menjadi rata-rata setiap bulan, pada gambar 3.2 dapat terlihat perbedaan yang mencolok antar bulan. Tetapi tetap saja prediksi berdasarkan rata-rata setiap bulan tidak dapat dilakukan karena tidak jelas pola yang dimiliki oleh setiap bulannya.

Data RTP juga diolah menjadi rata-rata setiap hari, pada gambar 3.3 didapati sebuah pola yaitu antara hari libur dengan hari kerja, terlihat perbedaannya yang mencolok.

karena data yang dimiliki telah di kelompokkan berdasarkan hari, yaitu Senin hingga Minggu, sehingga korelasi berisikan data hubungan hari yang sama pada berapa minggu sebelumnya.




**Gambar 3.3** Grafik RTP Rata-Rata Setiap Hari

### 3.2.4 Mencari Korelasi untuk Peramalan

Data yang telah diolah selanjutnya akan dianalisis untuk mencari pola yang serupa sebelum ditetapkan sebagai input pada proses peramalan yang akan dilakukan oleh ELM. Hal ini perlu dilakukan agar peramalan yang dilakukan oleh ELM akan memiliki error seminimal mungkin dan ELM dapat bekerja sesuai dengan kebutuhan. Pada gambar 3.2 terlihat ada korelasi yang tinggi antara hari senin saat ini dengan hari senin pada minggu yang lalu, selanjutnya hari senin pada 2 minggu sebelumnya juga memiliki korelasi yang tinggi. Pada hari Senin 3 minggu yang lalu juga masi memiliki korelasi yang tinggi dan

juga senin 4 minggu yang sebelumnya masih berada diatas 0,85. Untuk 5 dan 6 minggu sebelumnya, nilai korelasi juga masi tinggi yaitu diatas 0.8. sehingga 5 dan 6 minggu sebelumnya juga dapat digunakan sebagai cadangan dalam melakukan prediksi harga. Setelah mengamati gambar tersebut, didapatkan bahwa dengan melihat korelasi dan juga hari yang sama dapat membantu dalam melakukan prediksi harga pada hari yang sama karena dalam penelitian ini hanya menggunakan 3 input, akan dilakukan *trial and error* dalam menentukan kombinasi input yang dapat menghasilkan peramalan terbaik dengan error seminimal mungkin.



**Gambar 3.4** Korelasi hari Senin dengan Minggu Sebelumnya

### 3.2.5 Pembagian Data Training dan Testing

Proses training dan testing pada ELM merupakan proses yang sangat diperlukan. Proses training memiliki tujuan untuk mengembangkan model dari ELM, sementara proses testing digunakan untuk menguji kemampuan ELM sebagai alat peramal. Sehingga data yang telah diolah akan dibagi menjadi data training dan data testing.

Pada peramalan dengan ELM ini, model peramalan berdasarkan pada data training adalah:

$$y_{t-1} \text{ hasil training} = f(y_{t-2}, y_{t-3}, y_{t-4}, y_{t-5}) \quad (25)$$

Sementara model peramalan berdasarkan data testing adalah :

$$y_t \text{ hasil ramalan} = f(y_{t-1}, y_{t-2}, y_{t-3}, y_{t-4}) \quad (26)$$

### 3.2.6 Peramalan dengan Metode ELM

Ada beberapa tahap yang harus dilakukan untuk melakukan peramalan dengan metode ELM. Secara garis besar dapat dibagi menjadi empat tahap yaitu tahap preprocessing data, training, testing, kemudian melakukan analisis hasil peramalan sebelum dilakukan optimasi.

### 3.2.7 Training ELM

Sebelum ELM digunakan sebagai alat peramalan, perlunya dilakukan training pada ELM. Tujuan dari training adalah untuk mendapatkan input weight, bias, dan output weight dengan tingkat kesalahan yang rendah. Ada beberapa tahap yang harus dilakukan pada proses pelatihan ELM ini, yaitu:

#### 1. Normalisasi Data Training

Data yang akan diinput pada ELM perlu dinormalisasi agar mempunyai nilai pada range tertentu. Hal ini perlu dilakukan karena fungsi aktivasi yang digunakan untuk menghasilkan output dengan range [0,1] atau [-1,1]. Algoritma yang digunakan untuk normalisasi seperti pada [35], yaitu:

$$x_n = 2x \left( \frac{x_p - \min\{x_p\}}{(\max\{x_p\} - \min\{x_p\})} \right) - 1 \quad (27)$$

Dimana  $x_n$  adalah nilai hasil normalisasi,  $x_p$  nilai data asli yang belum dinormalisasi,  $\max\{x_p\}$  nilai maksimum pada data set, dan  $\min\{x_p\}$  merupakan nilai minimum pada data set.

#### 2. Menentukan Fungsi Aktivasi dan Jumlah *Hidden Neuron*

Selanjutnya, perlu ditentukannya fungsi aktivasi dan jumlah *hidden neuron* yang akan digunakan pada proses training ELM. Pada tugas akhir ini, fungsi aktivasi yang digunakan adalah logsig. Untuk jumlah *hidden neuron* akan ditentukan secara *trial and error* sehingga akan didapatkan

hasil peramalan dengan tingkat kesalahan yang kecil. Menurut [27], ELM akan menghasilkan output peramalan yang stabil jika menggunakan *hidden neuron* pada range 0-30. Namun jika output yang dihasilkan dari ELM kurang optimal, akan menggunakan fungsi aktivasi yang lain atau dengan mengubah jumlah *hidden neuron* hingga menghasilkan nilai yang optimal sesuai keinginan.

3. Menghitung *Input Weight, Bias dari Hidden Neuron, dan Output Weight*.

Dari proses training ELM akan diperoleh *input weight, output weight* dan *bias of hidden neuron* dengan tingkat kesalahan yang kecil diukur dengan parameter MSE dan MAPE. *Input weight* dan *bias of hidden neuron* ditentukan secara random, sedangkan *output weight* adalah hasil *invers* dari matriks hidden layer dan target output. Berikut persamaanya:

$$H\hat{\beta} = T \quad (28)$$

Dimana:

$$H(\omega_i, \dots, \omega_M, b_i, \dots, b_M, x_i, \dots, x_N) = \begin{bmatrix} g(\omega_1 x_1 + b_1) & \dots & g(\omega_M x_1 + b_M) \\ \vdots & & \vdots \\ g(\omega_1 x_N + b_i) & \dots & g(\omega_M x_N + b_M) \end{bmatrix}_{N \times M} \quad (29)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_M^T \end{bmatrix}_{M \times n} \quad (30)$$

$$T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times n} \quad (31)$$

$$\hat{\beta} = H^{-1}T \quad (32)$$

4. Denormalisasi Output Training

Output yang dihasilkan dari proses training didenormalisasikan sehingga akan didapatkan data prediksi dari proses training ELM. Rumus denormalisasi yang digunakan seperti pada [27] adalah:

$$x_d = 0.5 x (x_n + 1) x (\max\{x_p\} - \min\{x_p\}) + \min\{x_p\} \quad (33)$$

Dimana  $x_d$  adalah data setelah didenormalisasasi,  $x_n$  adalah output sebelum didenormalisasi,  $\min\{x_p\}$  adalah nilai minimum pada data set dan  $\max\{x_p\}$  merupakan nilai maksimum pada data set.

### 3.2.8 Testing ELM

Langkah selanjutnya setelah melewati proses *training* adalah melakukan testing ELM yang memiliki tujuan agar dapat mengetahui kemampuan ELM sebagai *forecasting tool*. Pada proses ini menggunakan input berupa *data testing*, *input weight*, *bias of hidden neuron* dan *output weight* yang telah diperoleh dari proses training. Pada tahap ini, data input akan dinormalisasi terlebih dulu sehingga memiliki range tertentu, dan outputnya pun didenormalisasi seperti pada proses training yang sebelumnya sehingga akan menghasilkan nilai output dengan nilai yang sebenarnya.

### 3.2.9 Analisis Hasil Peramalan

Setelah proses training dan testing dilakukan, maka akan muncul hasil peramalan dari ELM, yang selanjutnya hasil ramalan akan dianalisis untuk melihat apakah output dari peramalan tersebut memiliki error yang besar atau kecil. Jika error yang dihasilkan masih besar, maka harus dievaluasi kembali mulai dari proses training dan testing sehingga dapat diperoleh hasil yang optimal. Error pada ELM dapat diketahui dengan melihat besar nilai MSE dan MAPE pada proses testing yang dihasilkan. Rumus MSE dan MAPE yang digunakan untuk mengetahui seberapa besar error yang dihasilkan ELM adalah sebagai berikut:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - t_i)^2 \quad (34)$$


Dimana  $N$  merupakan jumlah data,  $y_i$  adalah output peramalan, dan  $t_i$  adalah data beban aktual. Sementara untuk MAPE adalah sebagai berikut:

$$\frac{1}{n} \sum_{i=1}^n \left| \frac{Y_{prediksi} - Y_{target}}{Y_{target}} \right| \cdot 100\% \quad (35)$$

Dimana  $n$  merupakan jumlah data yang diproses,  $Y_{prediksi}$  adalah nilai prediksi dari ANN, dan  $Y_{target}$  adalah nilai sebenarnya yang terjadi.

### 3.2.10 Penjadwalan Penggunaan Peralatan Listrik

Pada tugas akhir ini, telah diasumsikan penggunaan peralatan yang dimiliki berdasarkan jadwal kebiasaan konsumen yang ada di Indonesia. Gambar 3.5 Merupakan penggunaan peralatan listrik yang biasa dilakukan oleh konsumen di Indonesia.




**Gambar 3.5** Penggunaan Peralatan Listrik berdasarkan Kebiasaan Konsumen Indonesia

Setelah hasil peramalan didapatkan, maka akan dilakukan penjadwalan dalam menggunakan peralatan yang dimiliki. Penjadwalan akan dilakukan secara manual berdasarkan hasil peramalan. Pada gambar 3.6 merupakan hasil penjadwalan dalam menggunakan peralatan listrik oleh konsumen yang telah memiliki kemampuan peramalan harga listrik yang akan datang dalam melakukan manajemen energi skala rumah tangga. Dapat terlihat penjadwalan dilakukan dengan memindahkan waktu menggunakan peralatan listrik pada jam lain saat harga listrik lebih murah.

Perlu diketahui bahwa huruf abjad pada gambar mewakili peralatan yang telah disebutkan pada bab sebelumnya. Pada gambar, huruf A mewakili Lampu, huruf B mewakili Kulkas dan Freezer, huruf C



mewakili *Rice Cooker*, huruf D mewakili Panggangan Roti, huruf E mewakili TV, huruf F mewakili Pengering Rambut, huruf G mewakili Pencuci Piring, huruf H mewakili Pencuci Pakaian, huruf I mewakili Penyedot Debu, huruf J mewakili setrika, huruf K mewakili *Portable Computer*, huruf L mewakili *Air Conditioner*, huruf M mewakili Pompa Air, dan huruf N mewakili Pemanas Air.



**Gambar 3.6** Penggunaan Peralatan Listrik Setelah Terjadwal

### 3.3 Membandingkan Hasil Peramalan ELM dengan ANN

Kembali saat melakukan analisis pada hasil ramalan dengan metode ELM, setelah melakukan *training* dan *testing* akan didapatkan nilai MSE dan MAPE dari hasil penggunaan ELM untuk peramalan. MSE dan MAPE akan dibandingkan dengan MSE dan MAPE yang didapatkan oleh ANN (BP) yang digunakan juga sebagai metode peramalan. Sehingga dengan membandingkan antara ELM dan ANN (BP) akan dapat dilihat tingkat keakuratan dari setiap metode, baik dari segi besar error yang dihasilkan maupun waktu training dan testing yang dibutuhkan oleh setiap metode. Dengan membandingkan dengan ANN (BP) dapat juga di plot hasil ramalan yang dihasilkan dengan data aktual yang sebenarnya.

*Halaman ini sengaja dikosongkan*

## **BAB IV**

### **SIMULASI HASIL DAN PEMBAHASAN**

#### **4.1 Pengumpulan data**

Data RTP selama 2 tahun mulai 1 Januari 2016 hingga 31 Desember 2017 dan IBR pada tahun 2017 yang telah di dapatkan, diolah dengan bantuan *Microsoft Excell* dan matlab R2016a menggunakan metode ELM dan ANN. Sistem peramalan harga pada tugas akhir ini berdasarkan similar day, yaitu pola harga pada hari Senin pada Minggu ini diharapkan memiliki pola yang sama dengan hari Senin pada Minggu depan.

Data harga RTP setiap 24 jam selama 2 tahun mulanya dikelompokkan untuk setiap hari yang sama, yaitu Senin, Selasa, Rabu, Kamis, Jumat, Sabtu, dan Minggu. Selanjutnya dengan bantuan *Microsoft Excel*, dicari korelasi antara minggu ini dengan minggu sebelumnya dihari yang sama selama 24 jam. Pencarian korelasi sangat membantu untuk menganalisis minggu keberapa yang mempunyai korelasi terbesar terhadap minggu sekarang untuk diolah dengan menggunakan metode ELM dan ANN pada Matlab R2016a. Sedangkan data *Inclining Block Rate*, hanya mengambil data harga normal, batas penggunaan energi harga normal, dan harga saat penggunaan energi melebihi batas. Data RTP dan IBR yang digunakan dapat dilihat pada lampiran.

#### **4.2 Analisis Data dan Pembahasan**

Data harga listrik yang disediakan oleh layanan *Amereen Illinois Corporation* tiap jam selama satu hari diramal menggunakan metode ELM. Untuk mengetahui keakuratan metode ELM, ANN akan digunakan sebagai metode pembanding. Data harga listrik yang digunakan untuk peramalan pada tugas akhir ini adalah data harga listrik mulai mulai 1 Januari 2016 hingga 31 Desember 2017. Pada peramalan dengan ELM, dilakukan uji coba pada fungsi aktivasi dan jumlah *hidden neuron* yang berbeda. Fungsi aktivasi yang digunakan pada tugas akhir ini adalah fungsi aktivasi logsig. Sedangkan untuk jumlah *hidden neuron* menggunakan nilai 1 sampai 10 dan 15.

Berikut akan dijelaskan hasil ujicoba fungsi aktivasi logsig dengan jumlah hidden neuron dari 1 sampai 10 dan 15, serta presentase error dari masing-masing hidden neuron yang digunakan. kemudian akan dibandingkan dengan metode ANN, yang mana MSE, MAPE, dan training time sebagai parameter.

#### **4.2.1 Peramalan Harga Listrik Untuk Hari Senin**

Untuk peramalan harga hari Senin akan dibagi dalam dua proses, yaitu proses training dan testing. Peramalan dilakukan menggunakan ELM yang akan dibandingkan dengan ANN.

##### **4.2.1.1 Hasil Peramalan ELM untuk Harga Listrik Pada Hari Senin Menggunakan Fungsi Aktivasi Logsig**

Pada peramalan ini akan digunakan fungsi aktivasi logsig, karena data yang diramalkan memiliki nilai yang terletak antara 0 sampai 1.

Data harga energi listrik dari hari senin dibagi menjadi dua jenis, yaitu data training dan testing. Data training dan data testing ditentukan dari nilai terkecil MAPE yang didapatkan dari hasil testing untuk hari Senin ditanggal tertentu dengan cara trial and error menggunakan hidden neuron yang memiliki hasil terbaik. Sehingga banyaknya data training sebanyak  $n$  yang memiliki nilai minimum 24 karena data yang dimiliki adalah data harga setiap jam, sehingga untuk menggambarkan satu hari dibutuhkan minimal  $n$  dengan kelipatan 24, dan untuk data testing dimulai dengan range  $n + 1$  sampai  $n + 24$  agar mendapatkan hasil testing selama 1 hari.

Pada hari Senin ini, 3 data yang menjadi input untuk melakukan peramalan ini adalah data hari Senin 3 minggu sebelumnya, Senin 4 minggu sebelumnya, dan Senin 5 minggu sebelumnya. Hal ini tidak sesuai dengan korelasi yang besar pada Senin 1, 2, dan 3 minggu sebelumnya. Pertimbangan memilih Senin 3, 4, dan 5 minggu sebelumnya adalah karena pada saat itu didapatkan nilai MAPE dan MSE yang paling kecil dari percobaan yang lain.

Berikut hasil uji coba dengan fungsi aktivasi logsig dengan jumlah hidden neuron dari 1 sampai 10, dan 15.


**Tabel 4.1** Hasil Training ELM hari Senin dengan fungsi aktivasi Logsig.

Fungsi Aktivasi	Jumlah <i>Hidden Neuron</i>	MSE Training	MAPE Training (%)	Training Time (Detik)
Logsig	1	7.60E-05	24.25	0.0942
	2	7.64E-05	23.67	0.0990
	3	4.03E-05	14.34	0.1064
	4	4.02E-05	14.16	0.0852
	5	3.95E-05	14.07	0.0898
	6	3.98E-05	14.11	0.0868
	7	3.95E-05	14.31	0.0929
	8	3.99E-05	14.18	0.0862
	9	3.89E-05	14.03	0.0930
	10	3.87E-05	14.01	0.0931
	:	:	:	:
	15	3.86E-05	14.07	0.0950

Dengan fungsi aktivasi logsig, pada tabel 4.1 secara umum nilai MSE akan mengecil. Ketika menggunakan 1 hidden neuron, nilai MSE 7.60E-05, dan nilai MAPE 24.25%. Ketika menggunakan 3 hidden neuron, nilai MSE 4.03E-05 dan nilai MAPE 14.34% dan akan terus berkurang semakin bertambahnya *hidden neuron* hingga saat menggunakan 5 *hidden neuron*. Ketika menggunakan 6 *hidden neuron*, nilai MSE 3.98E-05 dan akan terus mengecil hingga menggunakan 15 *hidden neuron*. Sedangkan nilai MAPE 14.11% dan akan naik turun hingga menggunakan 15 hidden neuron yang memiliki selisih tidak jauh beda. Terlihat pada *hidden neuron* 1 sampai 5 nilai MSE turun, sedikit naik pada saat menggunakan 6 *hidden neuron* dan akan terus mengecil saat menggunakan 15 *hidden neuron*, nilai MAPE berubah-ubah. Jika dilihat dari waktu *training* yang dibutuhkan oleh masing-masing *hidden neuron*, tampak bahwa perbedaannya tidak terlalu besar dengan nilai minimum 0.0852 yang dimiliki 4 *hidden neuron* dan waktu maksimum adalah 0.1064 ketika menggunakan 3 *hidden neuron*. Ada beberapa hal yang sedikit kurang sesuai dengan [36] yang menjelaskan tentang sifat ELM yang memiliki training error kecil dan memiliki training speed yang cepat. Hal ini disebabkan banyaknya data yang diinputkan dan rendahnya

korelasi antar data sehingga nilai MAPE masih cukup besar. Banyak faktor yang harus lebih dikelompokkan untuk mendapat nilai error yang kecil karena memiliki korelasi yang tinggi antar data. Dapat dilihat pada gambar 4.1 hasil training ELM, terdapat beberapa data yang masi belum sesuai polanya.

Dari hasil training ELM yang ditunjukkan oleh tabel 4.1 didapatkan nilai yang bagus ketika menggunakan 15 hidden neuron dengan MSE 3.86E-05 dan MAPE 14.07%. *Input weight*, *bias of hidden neuron* dan *output weight* yang diperoleh dari 15 *hidden neuron* ini kemudian digunakan sebagai inputan pada proses *testing* untuk meramal harga listrik pada hari Senin tanggal 18 Desember 2017. Selain 15 *hidden neuron* dalam melakukan testing akan digunakan juga 14 *hidden neuron* karena nilai MSE dan MAPE *training* nya tidak kalah bagus dibanding dengan menggunakan 15 *hidden neuron* yaitu dengan MSE 3.87E-05 dan MAPE 14.01% sebagai trial and error dan akan diambil hasilnya yang terbaik untuk MSE dan MAPE *testing*.



**Gambar 4.1** Grafik perbandingan data histori dan data training ELM hari Senin ('logsig', 15 *hidden neuron*).

#### 4.2.1.2 Perbandingan Hasil Peramalan ELM untuk Harga Listrik Pada Hari Senin Menggunakan ELM dan ANN

Setelah melakukan peramalan dengan ELM, akan dibandingkan hasil ramalan tersebut dengan metode ANN sehingga dapat diketahui

metode mana yang lebih akurat dalam meramalkan harga listrik pada hari senin. Model ANN yang sering digunakan dalam melakukan peramalan adalah dengan menggunakan *Backpropagation* (BP). Algoritma BP menggunakan *error output* untuk mengubah nilai bobot-bobotnya dalam arah mundur (*Backward*). Untuk mendapatkan error ini, perlu tahap maju (*forward propagation*) harus dilakukan terlebih dahulu. Dengan metode BP ini akan dilihat hasil peramalan yang akan didapatkan, lalu akan dibandingkan dengan hasil ramalan ELM.

Untuk membandingkan ELM dengan ANN, parameter yang digunakan adalah MSE, MAPE, dan *Testing Time* yang akan disediakan dalam tabel perbandingan berikut ini.

**Tabel 4.2** Perbandingan parameter keakuratan metode ELM dan ANN.

Metode	MSE Training	MSE Testing	MAPE Training (%)	MAPE Testing (%)	Training Time (Detik)	Testing Time (Detik)
ELM	3.86E-05	9.20E-07	14.07	2.54	0.0950	0.0163
ANN	3.79E-05	9.63E-07	13.84	3.04	3.3948	2.1563

Dari tabel 4.2 perbandingan antara ELM dan ANN diatas dapat diketahui bahwa metode ELM memiliki keakuratan MSE dan MAPE *testing* yang lebih baik daripada ANN yaitu sebesar 9.20E-07 dan 2.54% untuk ELM sedangkan 9.63E-07 dan 3.04% untuk ANN. MSE dan MAPE *training*, nilai ANN sedikit lebih baik daripada ELM yaitu 3.86E-05 dan 14.07% untuk ELM serta 3.79E-05 dan 13.824% untuk ANN. Perbandingan *testing* maupun *training time*, jelas dapat dilihat bahwa ELM jauh lebih cepat jika dibandingkan dengan ANN yaitu 0.0163 dan 0.0950 untuk ELM serta 2.1563 dan 3.3948 untuk ANN. Hal ini menunjukkan bahwa ELM memiliki waktu yang lebih cepat dalam mengenali pola suatu data dan menghasilkan output dari ANN. Berikut tabel 4.2 yang berisikan data aktual dan peramalan dihari Senin beserta nilai error yang dapat dibandingkan antara ELM dan ANN.

**Tabel 4.3** Perbandingan data aktual dan data peramalan pada hari Senin.


Hari Senin, 18 Desember 2017					
Jam	Data Aktual (\$/kWh)	ELM (\$/kWh)	Error (%)	ANN (\$/kWh)	Error (%)
1	0.0199	0.0199	0.0040	0.0202	0.0156
2	0.0200	0.0199	0.0065	0.0202	0.0060
3	0.0197	0.0200	0.0147	0.0202	0.0264
4	0.0200	0.0201	0.0040	0.0203	0.0145
5	0.0208	0.0216	0.0355	0.0219	0.0518
6	0.0224	0.0255	0.1409	0.0250	0.1163
7	0.0292	0.0291	0.0055	0.0287	0.0188
8	0.0268	0.0267	0.0015	0.0260	0.0265
9	0.0261	0.0262	0.0038	0.0257	0.0149
10	0.0261	0.0253	0.0314	0.0249	0.0463
11	0.0247	0.0241	0.0231	0.0241	0.0243
12	0.0237	0.0235	0.0101	0.0235	0.0080
13	0.0232	0.0228	0.0168	0.0227	0.0190
14	0.0229	0.0227	0.0083	0.0226	0.0118
15	0.0224	0.0223	0.0049	0.0221	0.0143
16	0.0226	0.0226	0.0022	0.0224	0.0075
17	0.0278	0.0254	0.0847	0.0251	0.0969
18	0.0282	0.0267	0.0518	0.0269	0.0458
19	0.0257	0.0254	0.0101	0.0251	0.0199
20	0.0242	0.0242	0.0004	0.0242	0.0004
21	0.0225	0.0231	0.0244	0.0232	0.0302
22	0.0214	0.0221	0.0328	0.0218	0.0192
23	0.0198	0.0209	0.0551	0.0204	0.0339
24	0.0187	0.0194	0.0375	0.0198	0.0605
Maksimum Error		0.1409		0.1163	
Minimum Error		0.0004		0.0004	
Average Error		0.0254		0.0304	

Dapat dilihat pada tabel hasil peramalan diatas, error maksimum yang dimiliki oleh ELM yaitu sebesar 0.0291% Sedangkan eror maksimum yang dimiliki oleh ANN sebesar 0.3887%. Sedangkan eror minimum ELM sebesar 0.0051% yang juga sama dengan error minimum yang dimiliki oleh ANN. Dari sisi training dan testing time, ELM jauh lebih



cepat jika dibandingkan dengan ANN yaitu 0.0163 untuk testing ELM sedangkan 2.1563 untuk testing ANN dan 0.0950 untuk training ELM sedangkan 3.3948 untuk ANN. sehingga dapat dilihat bahwa ELM memiliki kemampuan meramal yang lebih baik dibandingkan dengan ANN karena memiliki kecepatan waktu dan error yang lebih kecil.

Plot data ramalan harga listrik dari Senin dengan metode ELM dan ANN disajikan pada gambar 4.2 dibawah. Dapat diketahui bahwa data ramalan yang dihasilkan oleh ELM (garis warna merah) memiliki hasil yang tidak jauh beda dengan hasil ramalan ANN (garis warna hijau). Hasil ramalan kedua metode ini hampir memiliki pola yang sama dengan data beban aktual (garis warna biru). Berikut grafik hasil peramalan ELM yang dibandingkan dengan peramalan BP untuk peramalan harga listrik hari Senin, 18 Desember 2017.



**Gambar 4.2** Grafik perbandingan data aktual, data ramalan ELM dan ANN untuk harga hari Senin, 18 Desember 2017.

#### 4.2.2 Peramalan Harga Listrik Untuk Hari Selasa

Untuk peramalan harga hari Selasa akan dibagi dalam dua proses, yaitu proses training dan testing. Peramalan dilakukan menggunakan ELM yang akan dibandingkan dengan ANN.

##### 4.2.2.1 Hasil Peramalan ELM untuk Harga Listrik Pada Hari Selasa Menggunakan Fungsi Aktivasi Logsig

Data harga listrik dari hari Selasa dibagi menjadi dua jenis, yaitu data *training* dan *testing*. Data *training* dan data *testing* ditentukan dari nilai terkecil MAPE yang didapatkan dari hasil *testing* untuk hari Selasa ditanggal tertentu dengan cara *trial and error* menggunakan

*hidden neuron* yang memiliki hasil terbaik. Sehingga banyaknya data *training* sebanyak  $n$  yang memiliki nilai minimum 24 karena data yang dimiliki adalah data harga setiap jam, untuk menggambarkan satu hari dibutuhkan minimal  $n$  dengan kelipatan 24, dan untuk data *testing* dimulai dengan range  $n + 1$  sampai  $n + 24$  agar mendapatkan hasil *testing* selama 1 hari.


Pada hari Selasa ini, 3 data yang menjadi input untuk melakukan permalan ini adalah data hari Selasa 1 minggu sebelumnya, Selasa 2 minggu sebelumnya, dan Selasa 3 minggu sebelumnya. Hal ini sesuai dengan korelasi yang besar pada Selasa 1, 2, dan 3 minggu sebelumnya. Pertimbangan memilih Selasa 1, 2, dan 3 minggu sebelumnya adalah selain memiliki korelasi yang besar dengan hari yang akan diramalkan, yaitu didapatkan nilai MAPE dan MSE yang paling kecil dari percobaan menggunakan kombinasi data yang lain.

**Tabel 4.4** Hasil Training ELM hari Selasa dengan fungsi aktivasi Logsig

Fungsi Aktivasi	Jumlah <i>Hidden Neuron</i>	MSE Training	MAPE Training (%)	Training Time (Detik)
Logsig	1	6.49E-05	22.60	0.0932
	2	4.99E-05	18.35	0.0894
	3	2.92E-05	12.46	0.0928
	4	2.47E-05	11.50	0.0870
	5	2.16E-05	10.74	0.0859
	6	2.25E-05	10.91	0.0905
	7	2.19E-05	10.70	0.0907
	8	2.11E-05	10.52	0.0914
	9	2.14E-05	10.51	0.0919
	10	2.12E-05	10.60	0.0922
	:	:	:	:
	15	2.05E-05	10.42	0.0951

Tabel 4.4 diatas adalah hasil uji coba dengan fungsi aktivasi logsig dengan jumlah *hidden neuron* dari 1 sampai 10, dan 15. Seperti peramalan harga pada hari Senin, untuk fungsi aktivasi logsig terlihat bahwa nilai MSE dan MAPE secara umum akan berkurang ketika *hidden neuron* bertambah. Namun terdapat kelainan di beberapa *hidden neuron*. Ketika menggunakan 1 *hidden neuron*, nilai MSE dan MAPE sebesar 6.49E-05 dan 22.60%. Selanjutnya MSE dan MAPE

turun hingga  $2.16\text{E-}05$  dan  $10.74$  saat menggunakan 5 *hidden neuron*. Saat menggunakan 6 *hidden neuron*, nilai MSE dan MAPE menjadi  $2.25\text{E-}05$  dan  $10.91$ , yang selanjutnya pada 7 sampai 10 *hidden neuron* memiliki nilai yang berubah-ubah. Jika dilihat dari waktu training yang dibutuhkan oleh masing-masing *hidden neuron*, tampak bahwa perbedaannya tidak terlalu besar dengan nilai minimum  $0.0859$  yang dimiliki 5 *hidden neuron* dan waktu maksimum adalah  $0.0932$  saat menggunakan 1 *hidden neuron*. pada 15 *hidden neuron*, didapatkan nilai MSE dan MAPE *training* terbaik dari *trial and error* yang dilakukan yaitu  $2.05\text{E-}05$  dan  $10.42$ . *Input weight*, *bias of hidden neuron* dan *output weight* yang diperoleh dari 15 *hidden neuron* ini kemudian digunakan sebagai inputan pada proses *testing* untuk meramal harga listrik pada hari Selasa untuk mendapatkan hasil *testing* yang terbaik.



**Gambar 4.3** Grafik perbandingan data histori dan data training ELM hari Senin ('logsig', 15 *hidden neuron*).

Jika dibandingkan dengan peramalan dihari senin, terdapat perbedaan yang signifikan, hal ini karena karakteristik harga yang berbeda sehingga ELM juga membaca pola yang berbeda.

Pada gambar 4.3 menunjukkan bahwa hasil training ELM untuk beban hari Selasa dengan fungsi aktivasi purelin dan jumlah *hidden neuron* 15 memiliki beberapa data yang masih belum sama dengan data aktual. Hal ini disebabkan banyaknya data yang diinputkan dan

rendahnya korelasi antar data sehingga nilai MAPE masih cukup besar. Banyak faktor yang harus lebih dikelompokkan untuk mendapat nilai error yang kecil karena memiliki korelasi yang tinggi antar data sehingga mempengaruhi ELM dalam mengenali pola data tersebut.

#### 4.2.2.2 Perbandingan Hasil Peramalan ELM untuk Harga Listrik Pada Hari Selasa Menggunakan ELM dan ANN

Setelah melakukan peramalan dengan ELM, akan dibandingkan hasil ramalan tersebut dengan metode ANN sehingga dapat diketahui metode mana yang lebih akurat dalam meramalkan harga listrik pada hari Selasa.

Untuk membandingkan ELM dengan ANN, parameter yang digunakan adalah MSE, MAPE, dan *Testing Time* yang akan disediakan dalam tabel perbandingan berikut ini.

**Tabel 4.5** Perbandingan parameter keakuratan metode ELM dan ANN.

Metode	MSE Training	MSE Testing	MAPE Training (%)	MAPE Testing (%)	Training Time (Detik)	Testing Time (Detik)
ELM	2.05E-05	1.77E-07	10.42	1.54	0.0951	0.0161
ANN	2.08E-05	4.75E-07	10.40	2.21	3.2381	2.3731


Dari tabel 4.5 perbandingan antara ELM dan ANN diatas dapat diketahui bahwa metode ELM memiliki keakuratan MSE dan MAPE testing yang lebih baik daripada ANN yaitu sebesar 1.77E-07 dan 1.54% untuk ELM sedangkan 4.75E-07 dan 2.21% untuk ANN. MSE *training* ELM sedikit lebih baik dari ANN yaitu 2.05E-05 untuk ELM dan 2.08E-05 untuk ANN, sedangkan nilai MAPE *training* ANN sedikit lebih baik daripada ELM yaitu 10.42% untuk ELM serta 10.4% untuk ANN. Perbandingan *training* maupun *testing time*, jelas dapat dilihat bahwa ELM jauh lebih cepat jika dibandingkan dengan ANN yaitu 0.0951 dan 0.0161 untuk ELM serta 3.2381 dan 2.3731 untuk ANN. Hal ini menunjukkan bahwa ELM memiliki waktu yang lebih cepat dalam mengenali pola suatu data dan menghasilkan output dari ANN.

**Tabel 4.6** Perbandingan data aktual dan data peramalan pada hari Selasa.

Hari Selasa, 8 Agustus 2017					
Jam	Data Aktual (\$/kWh)	ELM (\$/kWh)	Error (%)	ANN (\$/kWh)	Error (%)
1	0.0191	0.0196	0.0262	0.0195	0.0209
2	0.0183	0.0189	0.0328	0.0191	0.0437
3	0.0179	0.0186	0.0391	0.0188	0.0503
4	0.0178	0.0185	0.0393	0.0187	0.0506
5	0.0184	0.0188	0.0217	0.0188	0.0217
6	0.0201	0.0198	0.0149	0.0197	0.0199
7	0.0211	0.0208	0.0142	0.0207	0.0190
8	0.0221	0.0221	0.0000	0.0223	0.0090
9	0.0231	0.0232	0.0043	0.0234	0.0130
10	0.0254	0.0248	0.0236	0.0249	0.0197
11	0.0266	0.0265	0.0038	0.0266	0.0000
12	0.0279	0.0284	0.0179	0.0286	0.0251
13	0.0295	0.0298	0.0102	0.0295	0.0000
14	0.0321	0.0324	0.0093	0.0310	0.0343
15	0.0348	0.0346	0.0057	0.0333	0.0431
16	0.0370	0.0368	0.0054	0.0362	0.0216
17	0.0371	0.0367	0.0108	0.0361	0.0270
18	0.0326	0.0334	0.0245	0.0317	0.0276
19	0.0308	0.0302	0.0195	0.0297	0.0357
20	0.0283	0.0284	0.0035	0.0286	0.0106
21	0.0271	0.0271	0.0000	0.0273	0.0074
22	0.0238	0.0241	0.0126	0.0241	0.0126
23	0.0222	0.0224	0.0090	0.0223	0.0045
24	0.0208	0.0211	0.0144	0.0208	0.0000
Maksimum Error		0.0393		0.0506	
Minimum Error		0.0000		0.0000	
Average Error		0.0151		0.0216	

Pada tabel 4.6 dapat dilihat data besar error dari setiap jam yang dihasilkan oleh peramalan menggunakan metode ELM maupun ANN yang dibandingkan dengan data aktual. Dapat dilihat pada tabel diatas bahwa error maksimum ELM sebesar 0.0393% yang terdapat pada pola harga jam 4 pagi, sedangkan error minimum ELM sebesar 0.0000 berada pada harga pada jam 8 pagi dan 11 malam. untuk ANN error maksimum sebesar 0.0506 yang terjadi pada jam 4 pagi dan error

minimum sebesar 0.0000 pada jam 11 siang dan jam 12 malam. dapat dilihat bahwa error maksimum ELM lebih besar dari error maksimum yang dimiliki oleh ANN. Minimum error antara ELM dan ANN bernilai sama, yaitu 0.0000. sehingga dapat dilihat bahwa ELM memiliki kemampuan meramal yang lebih baik dibandingkan dengan ANN karena memiliki kecepatan waktu dan error yang lebih kecil. Plot data ramalan harga listrik dari Selasa dengan metode ELM dan ANN disajikan pada gambar 4.4 dibawah. Dapat diketahui bahwa data ramalan yang dihasilkan oleh ELM (garis warna merah) memiliki hasil yang tidak jauh beda dengan hasil ramalan ANN (garis warna hijau). Hasil ramalan kedua metode ini hampir memiliki pola yang sama dengan data beban aktual (garis warna biru).



**Gambar 4.4** Grafik perbandingan data aktual, data ramalan ELM dan ANN untuk harga hari Selasa, 8 Agustus 2017.

Gambar 4.4 adalah grafik hasil peramalan ELM yang dibandingkan dengan peramalan BP untuk peramalan harga listrik hari Selasa, 8 Agustus 2017.

### 4.2.3 Peramalan Harga Listrik Untuk Hari Rabu

Untuk peramalan harga hari Rabu akan dibagi dalam dua proses, yaitu proses training dan testing. Peramalan dilakukan menggunakan ELM yang akan dibandingkan dengan ANN.

#### 4.2.3.1 Hasil Peramalan ELM untuk Harga Listrik Pada Hari Rabu Menggunakan Fungsi Aktivasi Logsig

Data harga listrik dari hari Rabu dibagi menjadi dua jenis, yaitu data *training* dan *testing*. Data *training* dan data *testing* ditentukan dari

nilai terkecil MAPE yang didapatkan dari hasil *testing* untuk hari Rabu ditanggal tertentu dengan cara *trial and error* menggunakan *hidden neuron* yang memiliki hasil terbaik. Sehingga banyaknya data *training* sebanyak  $n$  yang memiliki nilai minimum 24 karena data yang dimiliki adalah data harga setiap jam, untuk menggambarkan satu hari dibutuhkan minimal  $n$  dengan kelipatan 24, dan untuk data *testing* dimulai dengan range  $n + 1$  sampai  $n + 24$  agar mendapatkan hasil *testing* selama 1 hari.

Pada hari Rabu ini, 3 data yang menjadi input untuk melakukan permalan ini adalah data hari Rabu 1 minggu sebelumnya, Rabu 2 minggu sebelumnya, dan Rabu 3 minggu sebelumnya. Hal ini sesuai dengan korelasi yang besar pada Rabu 1, 2, dan 3 minggu sebelumnya. Pertimbangan memilih Rabu 1, 2, dan 3 minggu sebelumnya adalah selain memiliki korelasi yang besar dengan hari yang akan diramalkan, yaitu didapatkan nilai MAPE dan MSE yang paling kecil dari percobaan menggunakan kombinasi data yang lain.

Tabel 4.7 adalah hasil uji coba dengan fungsi aktivasi logsig dengan jumlah hidden neuron dari 1 sampai 10, dan 15.

**Tabel 4.7** Hasil Training ELM hari Rabu dengan fungsi aktivasi Logsig.

Fungsi Aktivasi	Jumlah Hidden Neuron	MSE Training	MAPE Training (%)	Training Time (Detik)
Logsig	1	6.89E-05	24.33	0.1004
	2	6.53E-05	23.48	0.0869
	3	4.27E-05	16.92	0.0934
	4	3.20E-05	12.83	0.0967
	5	2.37E-05	11.39	0.0926
	6	2.14E-05	10.77	0.0915
	7	2.10E-05	10.77	0.0934
	8	2.10E-05	10.76	0.1068
	9	2.13E-05	10.94	0.0906
	10	2.12E-05	10.88	0.0945
	:	:	:	:
	15	2.11E-05	10.80	0.0854

Seperti peramalan harga pada hari sebelumnya, untuk fungsi aktivasi logsig terlihat bahwa nilai MSE dan MAPE secara umum akan


berkurang ketika *hidden neuron* bertambah. Namun terdapat kelainan di beberapa *hidden neuron*. Ketika menggunakan 1 *hidden neuron*, nilai MSE dan MAPE sebesar  $6.89E-05$  dan 24.33%. Selanjutnya MSE dan MAPE turun hingga  $2.10E-05$  dan 10.76% saat menggunakan 8 *hidden neuron*. Saat menggunakan 9 *hidden neuron*, nilai MSE dan MAPE menjadi  $2.13E-05$  dan 10.94%, yang selanjutnya pada 10 sampai 15 *hidden neuron* memiliki nilai yang terus turun.

Jika dilihat dari waktu *training* yang dibutuhkan oleh masing-masing *hidden neuron*, tampak bahwa perbedaannya tidak terlalu besar dengan nilai minimum 0.0854 yang dimiliki 15 *hidden neuron* dan waktu maksimum adalah 0.1068 ketika menggunakan 8 *hidden neuron*. Pada 15 *hidden neuron*, didapatkan nilai MSE dan MAPE *training* bukan yang terbaik dari *trial and error* yang dilakukan yaitu  $22.11E-05$  dan 10.80%. *Input weight*, *bias of hidden neuron* dan *output weight* yang diperoleh dari 15 *hidden neuron* ini kemudian digunakan sebagai inputan pada proses *testing* untuk meramal harga listrik pada hari Selasa untuk mendapatkan hasil *testing*. Selain 15 *hidden neuron*, akan dilakukan menggunakan 7 dan 8 *hidden neuron* untuk dilakukan *trial and error* hingga didapat nilai MSE dan MAPE *testing* terbaik dari menggunakan berapa *hidden neuron*.

Jika dibandingkan dengan peramalan dihari sebelumnya, terdapat perbedaan yang signifikan, hal ini karena karakteristik harga yang berbeda sehingga ELM juga membaca pola yang berbeda.

Pada gambar 4.5 menunjukkan bahwa hasil *training* ELM untuk beban hari Rabu dengan fungsi aktivasi *pureling* dan jumlah *hidden neuron* 15 memiliki beberapa data yang masih belum sama dengan data aktual. Hal ini disebabkan banyaknya data yang diinputkan dan rendahnya korelasi antar data sehingga nilai MAPE masih cukup besar. Banyak faktor yang harus lebih dikelompokkan untuk mendapat nilai error yang kecil karena memiliki korelasi yang tinggi antar data sehingga mempengaruhi ELM dalam mengenali pola data tersebut.





**Gambar 4.5** Grafik perbandingan data histori dan data training ELM hari Rabu ('logsig', 15 *hidden neuron*).

#### 4.2.3.2 Perbandingan Hasil Peramalan ELM untuk Harga Listrik Pada Hari Rabu Menggunakan ELM dan ANN

Setelah melakukan peramalan dengan ELM, akan dibandingkan hasil ramalan tersebut dengan metode ANN sehingga dapat diketahui metode mana yang lebih akurat dalam meramalkan harga listrik pada hari Rabu.

Untuk membandingkan ELM dengan ANN, parameter yang digunakan adalah MSE, MAPE, dan Testing Time yang akan disediakan dalam tabel perbandingan berikut ini.

Dari tabel 4.8 perbandingan antara ELM dan ANN diatas dapat diketahui bahwa metode ELM memiliki keakuratan MSE *testing* yang lebih baik daripada ANN yaitu sebesar 2.30E-07. Untuk MAPE yaitu

**Tabel 4.8** Perbandingan parameter keakuratan metode ELM dan ANN


Metode	MSE Training	MSE Testing	MAPE Training (%)	MAPE Testing (%)	Training Time (Detik)	Testing Time (Detik)
ELM	2.11E-05	2.30E-07	10.80	1.56	0.0854	0.0126
ANN	2.07E-05	4.76E-07	10.70	2.13	3.2568	2.1803

**Tabel 4.9** Perbandingan data aktual dan data peramalan pada hari Rabu.

Hari Rabu 9 Agustus 2017					
Jam	Data Aktual (\$/kWh)	ELM (\$/kWh)	Error (%)	ANN (\$/kWh)	Error (%)
1	0.0189	0.0190	0.0037	0.0189	0.0021
2	0.0179	0.0184	0.0245	0.0183	0.0229
3	0.0168	0.0181	0.0737	0.0181	0.0749
4	0.0169	0.0179	0.0567	0.0179	0.0597
5	0.0178	0.0185	0.0365	0.0184	0.0337
6	0.0193	0.0193	0.0016	0.0192	0.0047
7	0.0197	0.0202	0.0234	0.0201	0.0193
8	0.0217	0.0214	0.0129	0.0215	0.0101
9	0.0224	0.0226	0.0098	0.0228	0.0174
10	0.0247	0.0246	0.0049	0.0247	0.0020
11	0.0272	0.0263	0.0331	0.0262	0.0342
12	0.0275	0.0278	0.0105	0.0275	0.0015
13	0.0303	0.0302	0.0040	0.0294	0.0297
14	0.0330	0.0328	0.0049	0.0319	0.0318
15	0.0355	0.0345	0.0276	0.0338	0.0468
16	0.0368	0.0366	0.0043	0.0365	0.0076
17	0.0365	0.0365	0.0008	0.0359	0.0175
18	0.0324	0.0325	0.0031	0.0313	0.0345
19	0.0298	0.0300	0.0044	0.0292	0.0208
20	0.0273	0.0275	0.0066	0.0273	0.0000
21	0.0261	0.0263	0.0077	0.0264	0.0103
22	0.0231	0.0233	0.0095	0.0235	0.0195
23	0.0218	0.0216	0.0092	0.0216	0.0064
24	0.0203	0.0203	0.0020	0.0201	0.0059
Maksimum Error		0.0737		0.0749	
Minimum Error		0.0008		0.0000	
Average Error		0.0156		0.0214	

1.56% untuk ELM sedangkan  $4.76E-07$  dan 2.13% untuk ANN. MSE dan MAPE *training*, nilai ANN sedikit lebih baik daripada ELM yaitu  $2.11E-05$  dan 10.80% untuk ELM serta  $2.07E-05$  dan 10.70% untuk ANN. Perbandingan *training* maupun *testing time*, jelas dapat dilihat bahwa ELM jauh lebih cepat jika dibandingkan dengan ANN yaitu 0.0854 dan 0.0126 untuk ELM serta 3.2568 dan 2.1803 untuk ANN.

Pada tabel 4.9 dapat dilihat data besar error dari setiap jam yang dihasilkan oleh peramalan menggunakan metode ELM maupun ANN yang dibandingkan dengan data aktual. Dapat diamati bahwa error maksimum ELM sebesar 0.0737% yang terdapat pada pola harga jam 3 pagi, sedangkan error minimum ELM sebesar 0.0008% berada pada harga pada jam 5 sore. untuk ANN error maksimum sebesar 0.0749% yang terjadi pada jam 3 pagi dan error minimum sebesar 0.0000 pada jam 8 malam. Sehingga dari tabel dapat dilihat bahwa error maksimum ELM lebih kecil dari error maksimum yang dimiliki oleh ANN. Minimum error antara ELM dan ANN bernilai yaitu 0.0008% untuk ELM dan 0.0000% untuk ANN. sehingga dapat dilihat bahwa ELM memiliki kemampuan meramal yang lebih baik dibandingkan dengan ANN karena memiliki kecepatan waktu dan error yang lebih kecil.



**Gambar 4.6** Grafik perbandingan data aktual, data ramalan ELM dan ANN untuk harga hari Rabu, 9 Agustus 2017.

Plot data ramalan harga listrik dari Rabu dengan metode ELM dan ANN disajikan pada gambar 4.6 diatas. Dapat diketahui bahwa data ramalan yang dihasilkan oleh ELM (garis warna merah) memiliki hasil yang tidak jauh beda dengan hasil ramalan ANN (garis warna hijau). Hasil ramalan kedua metode ini hampir memiliki pola yang sama dengan data beban aktual (garis warna biru).

Gambar 4.6 adalah grafik hasil peramalan ELM yang dibandingkan dengan peramalan BP untuk peramalan harga listrik hari Rabu, 9 Agustus 2017.

#### 4.2.4 Peramalan Harga Listrik Untuk Hari Kamis

Untuk peramalan harga hari Kamis akan dibagi dalam dua proses, yaitu proses training dan testing. Peramalan dilakukan menggunakan ELM yang akan dibandingkan dengan ANN.

##### 4.2.4.1 Hasil Peramalan ELM untuk Harga Listrik Pada Hari Kamis Menggunakan Fungsi Aktivasi Logsig

Data harga listrik dari hari Kamis dibagi menjadi dua jenis, yaitu data *training* dan *testing*. Data *training* dan data *testing* ditentukan dari nilai terkecil MAPE yang didapatkan dari hasil *testing* untuk hari Kamis ditanggal tertentu dengan cara *trial and error* menggunakan *hidden neuron* yang memiliki hasil terbaik. Sehingga banyaknya data training sebanyak  $n$  yang memiliki nilai minimum 24 karena data yang dimiliki adalah data harga setiap jam, untuk menggambarkan satu hari dibutuhkan minimal  $n$  dengan kelipatan 24, dan untuk data testing dimulai dengan range  $n + 1$  sampai  $n + 24$  agar mendapatkan hasil testing selama 1 hari.

**Tabel 4.10** Hasil Training ELM hari Kamis dengan fungsi aktivasi Logsig

Fungsi Aktivasi	Jumlah Hidden Neuron	MSE Training	MAPE Training (%)	Training Time (Detik)
Logsig	1	7.26E-05	23.32	0.1141
	2	6.82E-05	22.96	0.1086
	3	5.62E-05	17.66	0.1046
	4	3.71E-05	14.08	0.1049
	5	3.51E-05	12.85	0.1080
	6	2.89E-05	11.32	0.1054
	7	2.84E-05	11.27	0.1053
	8	2.83E-05	11.21	0.1056
	9	2.81E-05	11.09	0.1090
	10	2.73E-05	11.04	0.0911
	:	:	:	:
	15	2.55E-05	10.88	0.0914

Pada hari Kamis ini, 3 data yang menjadi input untuk melakukan peramalan ini adalah data hari Kamis 1 minggu sebelumnya, Kamis 2 minggu sebelumnya, dan Kamis 3 minggu sebelumnya. Hal ini sesuai


dengan korelasi yang besar pada Kamis 1, 2, dan 3 minggu sebelumnya. Pertimbangan memilih Kamis 1, 2, dan 3 minggu sebelumnya adalah selain memiliki korelasi yang besar dengan hari yang akan diramalkan, yaitu didapatkan nilai MAPE dan MSE yang paling kecil dari percobaan menggunakan kombinasi data yang lain.

Seperti peramalan harga pada hari sebelumnya, untuk fungsi aktivasi logsig terlihat pada tabel 4.10 bahwa nilai MSE dan MAPE secara umum akan berkurang ketika *hidden neuron* bertambah. Berikut hasil uji coba dengan fungsi aktivasi logsig dengan jumlah *hidden neuron* dari 1 sampai 10, dan 15.

Ketika menggunakan 1 *hidden neuron*, nilai MSE dan MAPE sebesar 7.26E-05 dan 23.32%. Selanjutnya MSE dan MAPE turun hingga 3.51E-05 dan 12.85% saat menggunakan 5 *hidden neuron*. Nilai MSE dan MAPE pada hari Kamis akan terus berkurang sesuai dengan teori yang ada. Saat menggunakan 10 *hidden neuron*, nilai MSE dan MAPE menjadi 2.73E-05 dan 11.04%, yang selanjutnya pada 10 sampai 15 *hidden neuron* akan memiliki nilai yang terus turun. Jika dilihat dari waktu *training* yang dibutuhkan oleh masing-masing *hidden neuron*, tampak bahwa perbedaannya tidak terlalu besar dengan nilai minimum 0.0911 yang dimiliki 10 *hidden neuron* dan waktu maksimum adalah 0.1141 ketika menggunakan 1 *hidden neuron*. Pada 15 *hidden neuron*, didapatkan nilai MSE dan MAPE training terbaik dari trial and error yang dilakukan yaitu 2.55E-05 dan 10.88%. *Input weight*, *bias of hidden neuron* dan *output weight* yang diperoleh dari 15 *hidden neuron* ini kemudian digunakan sebagai inputan pada proses *testing* untuk meramal harga listrik pada hari Kamis hingga mendapatkan hasil testing yang terbaik.

Pada gambar 4.7 menunjukkan bahwa hasil training ELM untuk beban hari Kamis dengan fungsi aktivasi pureling dan jumlah *hidden neuron* 15 memiliki beberapa data yang masi belum sama dengan data aktual. Hal ini disebabkan banyaknya data yang diinputkan dan rendahnya korelasi antar data sehingga nilai MAPE masih cukup besar. Banyak faktor yang harus lebih dikelompokkan untuk mendapat nilai error yang kecil karena memiliki korelasi yang tinggi antar data sehingga mempengaruhi ELM dalam mengenali pola data tersebut.

Jika dibandingkan dengan peramalan dihari sebelumnya, terdapat perbedaan yang signifikan, hal ini karena karakteristkik harga yang berbeda sehingga ELM juga membaca pola yang berbeda.



**Gambar 4.7** Grafik perbandingan data histori dan data training ELM hari Kamis ('logsig', 15 *hidden neuron*).

#### 4.2.4.2 Perbandingan Hasil Peramalan ELM untuk Harga Listrik Pada Hari Kamis Menggunakan ELM dan AN

Setelah melakukan peramalan dengan ELM, akan dibandingkan hasil ramalan tersebut dengan metode ANN sehingga dapat diketahui metode mana yang lebih akurat dalam meramalkan harga listrik pada hari Kamis.

Untuk membandingkan ELM dengan ANN, parameter yang digunakan adalah MSE, MAPE, dan Testing Time yang akan disediakan dalam tabel perbandingan berikut ini.

**Tabel 4.11** Perbandingan parameter keakuratan metode ELM dan ANN.

Metode	MSE Training	MSE Testing	MAPE Training (%)	MAPE Testing (%)	Training Time (Detik)	Testing Time (Detik)
ELM	2.55E-05	3.69E-07	10.88	1.86	0.0914	0.0154
ANN	2.47E-05	4.43E-07	10.63	2.17	4.1157	2.4928

Dari tabel 4.11 perbandingan antara ELM dan ANN diatas dapat diketahui bahwa metode ELM memiliki keakuratan MSE dan MAPE

*testing* yang lebih baik daripada ANN yaitu sebesar  $3.69E-07$  dan  $1.86\%$  untuk ELM sedangkan  $4.43E-07$  dan  $2.17\%$  untuk ANN.

**Tabel 4.12** Perbandingan data aktual dan data peramalan pada hari Kamis.

Hari Kamis 29 Juni 2017					
Jam	Data Aktual (\$/kWh)	ELM (\$/kWh)	Error (%)	ANN (\$/kWh)	Error (%)
1	0.0189	0.0190	0.0053	0.0192	0.0159
2	0.0175	0.0178	0.0171	0.0184	0.0514
3	0.0170	0.0169	0.0059	0.0178	0.0471
4	0.0170	0.0170	0.0000	0.0178	0.0471
5	0.0183	0.0179	0.0219	0.0183	0.0000
6	0.0198	0.0202	0.0202	0.0199	0.0051
7	0.0209	0.0225	0.0766	0.0221	0.0574
8	0.0228	0.0244	0.0702	0.0240	0.0526
9	0.0247	0.0259	0.0486	0.0259	0.0486
10	0.0268	0.0269	0.0037	0.0269	0.0037
11	0.0286	0.0291	0.0175	0.0295	0.0315
12	0.0321	0.0321	0.0000	0.0322	0.0031
13	0.0356	0.0348	0.0225	0.0347	0.0253
14	0.0391	0.0387	0.0102	0.0381	0.0256
15	0.0415	0.0413	0.0048	0.0414	0.0024
16	0.0437	0.0430	0.0160	0.0440	0.0069
17	0.0432	0.0420	0.0278	0.0429	0.0069
18	0.0405	0.0396	0.0222	0.0397	0.0198
19	0.0353	0.0355	0.0057	0.0353	0.0000
20	0.0319	0.0318	0.0031	0.0320	0.0031
21	0.0305	0.0301	0.0131	0.0303	0.0066
22	0.0264	0.0268	0.0152	0.0270	0.0227
23	0.0242	0.0247	0.0207	0.0247	0.0207
24	0.0224	0.0222	0.0089	0.0221	0.0134
Maksimum Error		0.0766		0.0574	
Minimum Error		0.0000		0.0000	
Average Error		0.0190		0.0215	


MSE dan MAPE *training*, nilai ANN sedikit lebih baik daripada ELM yaitu  $2.55E-05$  dan  $10.88\%$  untuk ELM serta  $2.47E-05$  dan  $10.63\%$

untuk ANN. Perbandingan *training* maupun *testing time*, jelas dapat dilihat bahwa ELM jauh lebih cepat jika dibandingkan dengan ANN yaitu 0.0914 dan 0.0154 untuk ELM serta 4.1157 dan 2.4928 untuk ANN. Hal ini menunjukkan bahwa ELM memiliki waktu yang lebih cepat dalam mengenali pola suatu data dan menghasilkan output dari ANN.

Pada tabel 4.12 dapat dilihat data besar error dari setiap jam yang dihasilkan oleh peramalan menggunakan metode ELM maupun ANN yang dibandingkan dengan data aktual.

Hasil ramalan kedua metode ini hampir memiliki pola yang sama dengan data beban aktual (garis warna biru). Dapat diamati bahwa error maksimum ELM sebesar 0.0766% yang terdapat pada pola harga jam 7 pagi, sedangkan error minimum ELM sebesar 0.0000% berada pada harga pada jam 12 siang.

Untuk ANN error maksimum sebesar 0.0574% yang terjadi pada jam 7 pagi dan error minimum sebesar 0.0000 pada jam 5 pagi dan jam 7 malam. Sehingga dari tabel dapat dilihat bahwa error maksimum ELM tidak lebih kecil dari error maksimum yang dimiliki oleh ANN. Minimum error antara ELM dan ANN bernilai yaitu 0.0008% untuk ELM dan 0.0000% untuk ANN, tetapi ELM memiliki error rata-rata yang lebih kecil dibandingkan ANN yaitu 0.0190% untuk ELM dan 0.0215% untuk ANN. Dapat dilihat bahwa ELM memiliki kemampuan meramal yang lebih baik dibandingkan dengan ANN karena memiliki kecepatan waktu dan error lebih kecil.



**Gambar 4.8** Grafik perbandingan data aktual, data ramalan ELM dan ANN untuk harga hari Kamis, 29 Juni 2017.



Plot data ramalan harga listrik dari Kamis dengan metode ELM dan ANN disajikan pada gambar 4.8 dibawah. Dapat diketahui bahwa data ramalan yang dihasilkan oleh ELM (garis warna merah) memiliki hasil yang tidak jauh beda dengan hasil ramalan ANN (garis warna hijau). Gambar 4.8 adalah grafik hasil peramalan ELM yang dibandingkan dengan peramalan BP untuk peramalan harga listrik hari Kamis, 29 Juni 2017.

#### **4.2.5 Peramalan Harga Listrik Untuk Hari Jumat**

Untuk peramalan harga hari Jumat akan dibagi dalam dua proses, yaitu proses training dan testing. Peramalan dilakukan menggunakan ELM yang akan dibandingkan dengan ANN.

##### **4.2.5.1 Hasil Peramalan ELM untuk Harga Listrik Pada Hari Jumat Menggunakan Fungsi Aktivasi Logsig**

Data harga listrik dari hari Jumat dibagi menjadi dua jenis, yaitu data *training* dan *testing*. Data *training* dan data *testing* ditentukan dari nilai terkecil MAPE yang didapatkan dari hasil *testing* untuk hari Jumat ditanggal tertentu dengan cara trial and error menggunakan *hidden neuron* yang memiliki hasil terbaik. Sehingga banyaknya data *training* sebanyak  $n$  yang memiliki nilai minimum 24 karena data yang dimiliki adalah data harga setiap jam, untuk menggambarkan satu hari dibutuhkan minimal  $n$  dengan kelipatan 24, dan untuk data *testing* dimulai dengan range  $n + 1$  sampai  $n + 24$  agar mendapatkan hasil *testing* selama 1 hari.

Pada hari Jumat ini, 3 data yang menjadi input untuk melakukan permalan ini adalah data hari Jumat 1 minggu sebelumnya, Jumat 2 minggu sebelumnya, dan Jumat 4 minggu sebelumnya. Hal ini sesuai dengan korelasi yang besar pada Jumat 1, 2, dan 4 minggu sebelumnya. Pertimbangan memilih Jumat 1, 2, dan 4 minggu sebelumnya adalah selain memiliki korelasi yang besar dengan hari yang akan diramalkan, yaitu didapatkan nilai MAPE dan MSE yang paling kecil dari percobaan menggunakan kombinasi data yang lain. Berikut hasil uji coba dengan fungsi aktivasi logsig dengan jumlah *hidden neuron* dari 1 sampai 10, dan 15.


Seperti peramalan harga pada hari sebelumnya, untuk fungsi aktivasi Logsig terlihat pada tabel 4.13 bahwa nilai MSE dan MAPE secara umum akan berkurang ketika *hidden neuron* bertambah.

**Tabel 4.13** Hasil Training ELM hari Jumat dengan fungsi aktivasi Logsig

Fungsi Aktivasi	Jumlah Hidden Neuron	MSE Training	MAPE Training (%)	Training Time (Detik)
Logsig	1	6.29E-05	22.82	0.0990
	2	5.84E-05	20.37	0.0816
	3	3.53E-05	13.49	0.0945
	4	3.37E-05	12.89	0.0815
	5	2.66E-05	11.56	0.0892
	6	2.79E-05	11.72	0.0881
	7	2.60E-05	11.27	0.0882
	8	2.63E-05	11.23	0.0897
	9	2.61E-05	11.16	0.0845
	10	2.54E-05	11.12	0.0864
	:	:	:	:
	15	2.49E-05	11.12	0.0881

Ketika menggunakan 1 *hidden neuron*, nilai MSE dan MAPE sebesar 6.29E-05 dan 22.82%. Selanjutnya MSE dan MAPE turun hingga 2.66E-05 dan 11.56% saat menggunakan 5 *hidden neuron*. Nilai MSE dan MAPE pada hari Jumat secara umum akan terus berkurang sesuai dengan teori yang ada. Tetapi saat menggunakan 6 *hidden neuron*, nilai MSE dan MAPE menjadi 2.79E-05 dan 11.72%, nilai MSE dan MAPE selanjutnya naik turun secara tidak signifikan hingga menggunakan 10 *hidden neuron*, nilai MSE dan MAPE menjadi 2.54E-05 dan 11.12%, yang selanjutnya pada 10 sampai 15 *hidden neuron* akan memiliki nilai yang terus turun. Jika dilihat dari waktu *training* yang dibutuhkan oleh masing-masing *hidden neuron*, tampak bahwa perbedaannya tidak terlalu besar dengan nilai minimum 0.0815 yang dimiliki 4 *hidden neuron* dan waktu maksimum adalah 0.0990 ketika menggunakan 1 *hidden neuron*. Pada 15 *hidden neuron*, didapatkan nilai MSE dan MAPE training terbaik dari trial and error yang dilakukan yaitu 2.49E-05 dan 11.12%. *Input weight*, *bias of hidden neuron* dan *output weight* yang diperoleh dari 15 *hidden*

*neuron* ini kemudian digunakan sebagai inputan pada proses *testing* untuk meramal harga listrik pada hari Jumat untuk mendapatkan hasil *testing* yang terbaik.



**Gambar 4.9** Grafik perbandingan data histori dan data training ELM hari Jumat ('logsig', 15 *hidden neuron*).

Pada gambar 4.9 menunjukkan bahwa hasil training ELM untuk beban hari Jumat dengan fungsi aktivasi Logsig dan jumlah *hidden neuron* 15 memiliki beberapa data yang masi belum sama dengan data aktual. Hal ini disebabkan banyaknya data yang diinputkan dan rendahnya korelasi antar data sehingga nilai MAPE masih cukup besar.

Banyak faktor yang harus lebih dikelompokkan untuk mendapat nilai error yang kecil karena memiliki korelasi yang tinggi antar data sehingga mempengaruhi ELM dalam mengenali pola data tersebut.

Jika dibandingkan dengan peramalan dihari sebelumnya, terdapat perbedaan yang signifikan, hal ini karena karakteristik harga yang berbeda sehingga ELM juga membaca pola yang berbeda.

#### **4.2.5.2 Perbandingan Hasil Peramalan ELM untuk Harga Listrik Pada Hari Jumat Menggunakan ELM dan AN**

Setelah melakukan peramalan dengan ELM, akan dibandingkan hasil ramalan tersebut dengan metode ANN sehingga dapat diketahui metode mana yang lebih akurat dalam meramalkan harga listrik pada hari Jumat.

Untuk membandingkan ELM dengan ANN, parameter yang digunakan adalah MSE, MAPE, dan *Testing Time* yang akan disediakan dalam tabel perbandingan berikut ini.

**Tabel 4.14** Perbandingan parameter keakuratan metode ELM dan ANN.

Metode	MSE Training	MSE Testing	MAPE Training (%)	MAPE Testing (%)	Training Time (Detik)	Testing Time (Detik)
ELM	2.49E-05	3.88E-07	11.12	1.81	0.0881	0.0165
ANN	2.49E-05	4.45E-07	11.02	2.08	3.1786	2.1966

Dari tabel 4.14 perbandingan antara ELM dan ANN diatas dapat diketahui bahwa metode ELM memiliki keakuratan MSE dan MAPE *testing* yang lebih baik daripada ANN yaitu sebesar 2.49E-05 dan 1.81% untuk ELM sedangkan 4.45E-07 dan 2.08% untuk ANN.

MSE dan MAPE *training*, nilai MSE *training* ANN bernilai sama dengan ELM yaitu 2.49E-05 tetapi nilai MAPE *training* ANN lebih baik daripada MAPE *training* ELM yaitu 11.12% untuk ELM dan 11.02% untuk ANN. Perbandingan *training* maupun *testing time*, jelas dapat dilihat bahwa ELM jauh lebih cepat jika dibandingkan dengan ANN yaitu 0.0881 dan 0.0165 untuk ELM serta 3.1786 dan 2.1966 untuk ANN. Hal ini menunjukkan bahwa ELM memiliki waktu yang lebih cepat dalam mengenali pola suatu data dan menghasilkan output dari ANN.

Pada tabel 4.15 dapat dilihat data besar error dari setiap jam yang dihasilkan oleh peramalan menggunakan metode ELM maupun ANN yang dibandingkan dengan data aktual. Dapat diamati bahwa error maksimum ELM sebesar 0.0469% yang terdapat pada pola harga jam 10 malam, sedangkan error minimum ELM sebesar 0.0000% berada pada harga pada jam 5 pagi, 4 sore dan 12 malam.

ANN memiliki error maksimum sebesar 0.0547% yang terjadi pada jam 10 malam dan error minimum sebesar 0.0000 pada jam 12 malam. Sehingga dari tabel dapat dilihat bahwa error maksimum ELM lebih kecil dari error maksimum yang dimiliki oleh ANN. Minimum error antara ELM dan ANN bernilai sama yaitu 0.0000%, tetapi ELM

memiliki error rata-rata yang lebih kecil dibandingkan ANN yaitu 0.0184% untuk ELM dan 0.0210% untuk ANN.


**Tabel 4.15** Perbandingan data aktual dan data peramalan pada hari Jumat.

Hari Jumat, 30 Juni 2017					
Jam	Data Aktual (\$/kWh)	ELM (\$/kWh)	Error (%)	ANN (\$/kWh)	Error (%)
1	0.0207	0.0213	0.0290	0.0213	0.0290
2	0.0199	0.0206	0.0352	0.0208	0.0452
3	0.0196	0.0193	0.0153	0.0201	0.0255
4	0.0196	0.0191	0.0255	0.0200	0.0204
5	0.0201	0.0201	0.0000	0.0206	0.0249
6	0.0215	0.0220	0.0233	0.0219	0.0186
7	0.0234	0.0242	0.0342	0.0240	0.0256
8	0.0252	0.0257	0.0198	0.0258	0.0238
9	0.0274	0.0272	0.0073	0.0275	0.0036
10	0.0285	0.0288	0.0105	0.0292	0.0246
11	0.0301	0.0311	0.0332	0.0314	0.0432
12	0.0336	0.0344	0.0238	0.0340	0.0119
13	0.0362	0.0371	0.0249	0.0365	0.0083
14	0.0401	0.0406	0.0125	0.0406	0.0125
15	0.0418	0.0429	0.0263	0.0431	0.0311
16	0.0442	0.0442	0.0000	0.0440	0.0045
17	0.0417	0.0421	0.0096	0.0420	0.0072
18	0.0373	0.0384	0.0295	0.0378	0.0134
19	0.0338	0.0337	0.0030	0.0334	0.0118
20	0.0299	0.0303	0.0134	0.0307	0.0268
21	0.0284	0.0288	0.0141	0.0292	0.0282
22	0.0256	0.0268	0.0469	0.0270	0.0547
23	0.0239	0.0240	0.0042	0.0237	0.0084
24	0.0217	0.0217	0.0000	0.0217	0.0000
Maksimum Error		0.0469		0.0547	
Minimum Error		0.0000		0.0000	
Average Error		0.0184		0.0210	

Sehingga dapat dilihat bahwa ELM memiliki kemampuan meramal yang lebih baik dibandingkan dengan ANN karena memiliki kecepatan waktu dan error yang lebih kecil.

Plot data ramalan harga listrik dari Jumat dengan metode ELM dan ANN disajikan pada gambar 4.10 dibawah. Dapat diketahui bahwa

data ramalan yang dihasilkan oleh ELM (garis warna merah) memiliki hasil yang tidak jauh beda dengan hasil ramalan ANN (garis warna hijau).



**Gambar 4.10** Grafik perbandingan data aktual, data ramalan ELM dan ANN untuk harga hari Jumat, 30 Juni 2017.

Hasil ramalan kedua metode ini hampir memiliki pola yang sama dengan data beban aktual (garis warna biru). Gambar 4.10 adalah grafik hasil peramalan ELM yang dibandingkan dengan peramalan BP untuk peramalan harga listrik hari Jumat, 30 Juni 2017.

#### 4.2.6 Peramalan Harga Listrik Untuk Hari Sabtu

Untuk peramalan harga hari Sabtu akan dibagi dalam dua proses, yaitu proses *training* dan *testing*. Peramalan dilakukan menggunakan ELM yang akan dibandingkan dengan ANN.

##### 4.2.6.1 Hasil Peramalan ELM untuk Harga Listrik Pada Hari Sabtu Menggunakan Fungsi Aktivasi Logsig

Data harga listrik dari hari Sabtu dibagi menjadi dua jenis, yaitu data *training* dan *testing*. Data *training* dan data *testing* ditentukan dari nilai terkecil MAPE yang didapatkan dari hasil testing untuk hari Sabtu ditanggal tertentu dengan cara *trial and error* menggunakan *hidden neuron* yang memiliki hasil terbaik. Sehingga banyaknya data *training* sebanyak  $n$  yang memiliki nilai minimum 24 karena data yang dimiliki adalah data harga setiap jam, untuk menggambarkan satu hari dibutuhkan minimal  $n$  dengan kelipatan 24, dan untuk data *testing* dimulai dengan range  $n + 1$  sampai  $n + 24$  agar mendapatkan hasil *testing* selama 1 hari. Pada hari Sabtu ini, 3 data yang menjadi input untuk melakukan peramalan ini adalah data hari Sabtu 1 minggu

sebelumnya, Sabtu 2 minggu sebelumnya, dan Sabtu 4 minggu sebelumnya. Hal ini sesuai dengan korelasi yang besar pada Sabtu 1, 2, dan 4 minggu sebelumnya. Pertimbangan memilih Sabtu 1, 2, dan 4 minggu sebelumnya adalah selain memiliki korelasi yang besar dengan hari yang akan diramalkan, yaitu didapatkan nilai MAPE dan MSE yang paling kecil dari percobaan menggunakan kombinasi data yang lain.


Berikut hasil uji coba dengan fungsi aktivasi logsig dengan jumlah *hidden neuron* dari 1 sampai 10, dan 15. Seperti peramalan harga pada hari sebelumnya, untuk fungsi aktivasi Logsig terlihat bahwa nilai MSE dan MAPE secara umum akan berkurang ketika *hidden neuron* bertambah. Ketika menggunakan 1 *hidden neuron*, nilai MSE dan MAPE sebesar 3.49E-05 dan 18.08%. Selanjutnya MSE dan MAPE turun hingga 1.49E-05 dan 10.43% saat menggunakan 7 *hidden neuron*.

**Tabel 4.16** Hasil Training ELM hari Sabtu dengan fungsi aktivasi Logsig.

Fungsi Aktivasi	Jumlah <i>Hidden Neuron</i>	MSE Training	MAPE Training (%)	Training Time (Detik)
Logsig	1	3.49E-05	18.08	0.0861
	2	1.80E-05	11.62	0.0908
	3	1.60E-05	10.82	0.0828
	4	1.56E-05	10.66	0.0950
	5	1.53E-05	10.54	0.0964
	6	1.54E-05	10.69	0.0891
	7	1.49E-05	10.43	0.0886
	8	1.51E-05	10.55	0.0966
	9	1.49E-05	10.41	0.0907
	10	1.50E-05	10.56	0.0880
	:	:	:	:
	15	1.48E-05	10.41	0.1081

Nilai MSE dan MAPE pada hari Sabtu secara umum akan terus berkurang sesuai dengan teori yang ada. Tetapi saat menggunakan 8 *hidden neuron*, nilai MSE dan MAPE menjadi 1.51E-05 dan 10.55%, nilai MSE dan MAPE selanjutnya naik turun secara tidak signifikan hingga menggunakan 10 *hidden neuron*, nilai MSE dan MAPE menjadi 1.50E-05 dan 10.56%, yang selanjutnya pada 10 sampai 15

hidden neuron akan memiliki nilai yang terus turun. Pada 15 *hidden neuron*, didapatkan nilai MSE dan MAPE training terbaik dari *trial and error* yang dilakukan  $1.48\text{E-}05$  dan  $10.41\%$ . Jika dilihat dari waktu *training* yang dibutuhkan oleh masing-masing hidden neuron, tampak bahwa perbedaannya tidak terlalu besar dengan nilai minimum 0.0828 yang dimiliki 3 *hidden neuron* dan waktu maksimum adalah 0.1081 ketika menggunakan 15 *hidden neuron*. *Input weight*, *bias of hidden neuron* dan *output weight* yang diperoleh dari 15 *hidden neuron* ini kemudian digunakan sebagai inputan pada proses *testing* untuk meramal harga listrik pada hari Sabtu untuk mendapatkan hasil *testing* yang terbaik.



**Gambar 4.11** Grafik perbandingan data histori dan data training ELM hari Sabtu ('logsig', 15 *hidden neuron*).

Pada gambar 4.11 menunjukkan bahwa hasil training ELM untuk beban hari Sabtu dengan fungsi aktivasi Logsig dan jumlah *hidden neuron* 15 memiliki beberapa data yang masi belum sama dengan data aktual. Hal ini disebabkan banyaknya data yang diinputkan dan rendahnya korelasi antar data sehingga nilai MAPE masih cukup besar. Banyak faktor yang harus lebih dikelompokkan untuk mendapat nilai error yang kecil karena memiliki korelasi yang tinggi antar data sehingga mempengaruhi ELM dalam mengenali pola data tersebut.



Jika dibandingkan dengan peramalan dihari sebelumnya, terdapat perbedaan yang signifikan, hal ini karena karakteristik harga yang berbeda sehingga ELM juga membaca pola yang berbeda.

#### 4.2.6.2 Perbandingan Hasil Peramalan ELM untuk Harga Listrik Pada Hari Sabtu Menggunakan ELM dan AN

Setelah melakukan peramalan dengan ELM, akan dibandingkan hasil ramalan tersebut dengan metode ANN sehingga dapat diketahui metode mana yang lebih akurat dalam meramalkan harga listrik pada hari Sabtu.

Untuk membandingkan ELM dengan ANN, parameter yang digunakan adalah MSE, MAPE, dan *Testing Time* yang akan disediakan dalam tabel 4.17. Terlihat bahwa perbandingan antara ELM dan ANN diatas dapat diketahui bahwa metode ELM memiliki keakuratan MSE dan MAPE *testing* yang lebih baik daripada ANN yaitu sebesar 2.20E-07 dan 1.65% untuk ELM sedangkan 4.50E-07 dan 2.35% untuk ANN. MSE dan MAPE training, nilai MSE *training* ANN bernilai lebih baik dari ELM yaitu 1.48E-05 untuk ELM sedangkan ANN bernilai 1.45E-05. Tetapi nilai MAPE *training* ELM

**Tabel 4.17** Perbandingan parameter keakuratan metode ELM dan ANN

Metode	MSE Training	MSE Testing	MAPE Training (%)	MAPE Testing (%)	Training Time (Detik)	Testing Time (Detik)
ELM	1.48E-05	2.20E-07	10.41	1.65	0.1081	0.0168
ANN	1.45E-05	4.50E-07	10.46	2.35	3.2115	2.2323

lebih baik daripada MAPE *training* ANN yaitu 10.41% untuk ELM dan 10.46% untuk ANN. Perbandingan *training* maupun *testing time*, jelas dapat dilihat bahwa ELM jauh lebih cepat jika dibandingkan dengan ANN yaitu 0.1081 dan 0.0168 untuk ELM serta 3.2115 dan 2.2323 untuk ANN. Hal ini menunjukkan bahwa ELM memiliki waktu yang lebih cepat dalam mengenali pola suatu data dan menghasilkan output dari ANN.

Pada tabel 4.18 dapat dilihat data besar error dari setiap jam yang dihasilkan oleh peramalan menggunakan metode ELM maupun ANN

yang dibandingkan dengan data aktual. Dapat diamati bahwa error maksimum ELM sebesar 0.0481% yang terdapat pada pola harga jam 7 malam, sedangkan error minimum ELM sebesar 0.0053% berada pada harga pada jam 3 pagi.


**Tabel 4.18** Perbandingan data aktual dan data peramalan pada hari Sabtu.

Hari Sabtu, 1 Juli 2017					
Jam	Data Aktual (\$/kWh)	ELM (\$/kWh)	Error (%)	ANN (\$/kWh)	Error (%)
1	0.0201	0.0204	0.0149	0.0202	0.0050
2	0.0191	0.0193	0.0105	0.0193	0.0105
3	0.0187	0.0188	0.0053	0.0190	0.0160
4	0.0181	0.0182	0.0055	0.0186	0.0276
5	0.0179	0.0182	0.0168	0.0185	0.0335
6	0.0184	0.0188	0.0217	0.0189	0.0272
7	0.0192	0.0198	0.0313	0.0196	0.0208
8	0.0212	0.0220	0.0377	0.0221	0.0425
9	0.0231	0.0236	0.0216	0.0243	0.0519
10	0.0243	0.0248	0.0206	0.0254	0.0453
11	0.0257	0.0260	0.0117	0.0263	0.0233
12	0.0269	0.0272	0.0112	0.0269	0.0000
13	0.0281	0.0286	0.0178	0.0276	0.0178
14	0.0293	0.0305	0.0410	0.0290	0.0102
15	0.0305	0.0317	0.0393	0.0307	0.0066
16	0.0327	0.0336	0.0275	0.0334	0.0214
17	0.0326	0.0337	0.0337	0.0339	0.0399
18	0.0304	0.0318	0.0461	0.0315	0.0362
19	0.0270	0.0283	0.0481	0.0274	0.0148
20	0.0256	0.0262	0.0234	0.0263	0.0273
21	0.0246	0.0252	0.0244	0.0257	0.0447
22	0.0233	0.0237	0.0172	0.0244	0.0472
23	0.0212	0.0218	0.0283	0.0219	0.0330
24	0.0199	0.0207	0.0402	0.0205	0.0302
Maksimum Error		0.0481		0.0519	
Minimum Error		0.0053		0.0000	
Average Error		0.0248		0.0264	

ANN memiliki error maksimum sebesar 0.0519% yang terjadi pada jam 9 pagi dan error minimum sebesar 0.0000 pada jam 12 siang. Sehingga dari tabel dapat dilihat bahwa error maksimum ELM lebih kecil dari error maksimum yang dimiliki oleh ANN.

Minimum error antara ELM dan ANN bernilai 0.0053% 0.0000%, tetapi ELM memiliki error rata-rata yang lebih kecil dibandingkan ANN yaitu 0.0248% untuk ELM dan 0.0264% untuk ANN. Sehingga dapat dilihat bahwa ELM memiliki kemampuan meramal yang lebih baik dibandingkan dengan ANN karena memiliki kecepatan waktu dan error yang lebih kecil.

Plot data ramalan harga listrik dari Sabtu dengan metode ELM dan ANN disajikan pada gambar 4.12 dibawah. Dapat diketahui bahwa data ramalan yang dihasilkan oleh ELM (garis warna merah) memiliki hasil yang tidak jauh beda dengan hasil ramalan ANN (garis warna hijau). Hasil ramalan kedua metode ini hampir memiliki pola yang sama dengan data beban aktual (garis warna biru). Berikut grafik hasil peramalan ELM yang dibandingkan dengan peramalan BP untuk peramalan harga listrik hari Sabtu, 1 Juli 2017.



**Gambar 4.12** Grafik perbandingan data aktual, data ramalan ELM dan ANN untuk harga hari Sabtu, 1 Juli 2017.

#### 4.2.7 Peramalan Harga Listrik Untuk Hari Minggu

Untuk peramalan harga hari Minggu akan dibagi dalam dua proses, yaitu proses *training* dan *testing*. Peramalan dilakukan menggunakan ELM yang akan dibandingkan dengan ANN.

#### 4.2.7.1 Hasil Peramalan ELM untuk Harga Listrik Pada Hari Minggu Menggunakan Fungsi Aktivasi Logsig

Data harga listrik dari hari Minggu dibagi menjadi dua jenis, yaitu data *training* dan *testing*. Data *training* dan data *testing* ditentukan dari nilai terkecil MAPE yang didapatkan dari hasil *testing* untuk hari Minggu ditanggal tertentu dengan cara *trial and error* menggunakan *hidden neuron* yang memiliki hasil terbaik. Sehingga banyaknya data *training* sebanyak  $n$  yang memiliki nilai minimum 24 karena data yang dimiliki adalah data harga setiap jam, untuk menggambarkan satu hari dibutuhkan minimal  $n$  dengan kelipatan 24, dan untuk data *testing* dimulai dengan range  $n + 1$  sampai  $n + 24$  agar mendapatkan hasil *testing* selama 1 hari.


**Tabel 4.19** Hasil Training ELM hari Minggu dengan fungsi aktivasi Logsig.

Fungsi Aktivasi	Jumlah Hidden Neuron	MSE Training	MAPE Training (%)	Training Time (Detik)
Logsig	1	4.25E-05	21.14	0.0829
	2	3.46E-05	16.95	0.0906
	3	2.64E-05	14.54	0.0869
	4	2.26E-05	12.80	0.0852
	5	2.04E-05	11.93	0.0929
	6	1.98E-05	12.04	0.1066
	7	1.93E-05	11.83	0.0895
	8	1.93E-05	12.00	0.0889
	9	1.90E-05	11.75	0.0865
	10	1.88E-05	11.61	0.0844
	:	:	:	:
	15	1.84E-05	11.47	0.0858

Pada hari Minggu ini, 3 data yang menjadi input untuk melakukan peramalan ini adalah data hari Minggu 1 minggu sebelumnya, Minggu 2 minggu sebelumnya, dan Minggu 3 minggu sebelumnya. Hal ini sesuai dengan korelasi yang besar pada Minggu 1, 2, dan 3 minggu sebelumnya. Pertimbangan memilih Minggu 1, 2, dan 3 minggu sebelumnya adalah selain memiliki korelasi yang besar dengan hari yang akan diramalkan, yaitu didapatkan nilai MAPE dan MSE yang paling kecil dari percobaan menggunakan kombinasi data yang lain.

Berikut hasil uji coba dengan fungsi aktivasi logsig dengan jumlah hidden neuron dari 1 sampai 10, dan 15.

Seperti peramalan harga pada hari sebelumnya, untuk fungsi aktivasi Logsig terlihat pada tabel 4.19 bahwa nilai MSE dan MAPE secara umum akan berkurang ketika hidden neuron bertambah. Ketika menggunakan 1 *hidden neuron*, nilai MSE dan MAPE sebesar  $4.25\text{E-}05$  dan 21.14%. Selanjutnya MSE dan MAPE turun hingga  $2.04\text{E-}05$  dan 11.93% saat menggunakan 5 *hidden neuron*. Nilai MSE dan MAPE pada hari Minggu secara umum akan terus berkurang sesuai dengan teori yang ada. Tetapi saat menggunakan 6 *hidden neuron*, nilai MSE dan MAPE menjadi  $1.98\text{E-}05$  dan 12.04%, nilai MSE akan selalu turun hingga menggunakan 15 *hidden neuron* tetapi MAPE selanjutnya naik turun secara tidak signifikan hingga menggunakan 10 hidden neuron, nilai MSE dan MAPE menjadi  $1.88\text{E-}05$  dan 11.61%, yang selanjutnya pada 10 sampai 15 *hidden neuron* akan memiliki nilai yang terus turun. Jika dilihat dari waktu *training* yang dibutuhkan oleh masing-masing *hidden neuron*, tampak bahwa perbedaannya tidak



**Gambar 4.13** Grafik perbandingan data historis dan data training ELM hari Minggu ('logsig', 15 hidden neuron).

terlalu besar dengan nilai minimum 0.0829 yang dimiliki 1 hidden neuron dan waktu maksimum adalah 0.1066 ketika menggunakan 6 hidden neuron.

*Input weight, bias of hidden neuron* dan *output weight* yang diperoleh dari 15 *hidden neuron* ini kemudian digunakan sebagai inputan pada proses *testing* untuk meramal harga listrik pada hari Selasa untuk mendapatkan hasil testing. Selain 15 *hidden neuron*, akan dilakukan menggunakan 5 *hidden neuron* untuk dilakukan *trial and error* hingga didapat nilai MSE dan MAPE *testing* terbaik dari menggunakan berapa *hidden neuron*.

Pada gambar 4.13 menunjukkan bahwa hasil *training* ELM untuk beban hari Minggu dengan fungsi aktivasi Logsig dan jumlah hidden neuron 15 memiliki beberapa data yang masi belum sama dengan data aktual. Hal ini disebabkan banyaknya data yang diinputkan dan rendahnya korelasi antar data sehingga nilai MAPE masih cukup besar. Banyak faktor yang harus lebih dikelompokkan untuk mendapat nilai error yang kecil karena memiliki korelasi yang tinggi antar data sehingga mempengaruhi ELM dalam mengenali pola data tersebut. Jika dibandingkan dengan peramalan dihari sebelumnya, terdapat perbedaan yang signifikan, hal ini karena karakteristik harga yang berbeda sehingga ELM juga membaca pola yang berbeda.

#### 4.2.7.2 Perbandingan Hasil Peramalan ELM untuk Harga Listrik Pada Hari Minggu Menggunakan ELM dan AN

Setelah melakukan peramalan dengan ELM, akan dibandingkan hasil ramalan tersebut dengan metode ANN sehingga dapat diketahui metode mana yang lebih akurat dalam meramalkan harga listrik pada hari Minggu.

**Tabel 4.20** Perbandingan parameter keakuratan metode ELM dan ANN.

Metode	MSE Training	MSE Testing	MAPE Training (%)	MAPE Testing (%)	Training Time (Detik)	Testing Time (Detik)
ELM	2.04E-05	1.99E-07	11.93	1.58	0.0929	0.0177
ANN	1.85E-05	8.16E-07	11.53	2.35	3.2914	2.2076

Untuk membandingkan ELM dengan ANN, parameter yang digunakan adalah MSE, MAPE, dan Testing Time yang akan disediakan dalam tabel perbandingan diatas.

**Tabel 4.21** Perbandingan data aktual dan data peramalan pada hari Minggu.  
Hari Minggu, 26 November 2017

Jam	Data Aktual (\$/kWh)	ELM (\$/kWh)	Error (%)	ANN (\$/kWh)	Error (%)
1	0.0207	0.0206	0.0048	0.0204	0.0145
2	0.0205	0.0206	0.0049	0.0203	0.0098
3	0.0203	0.0207	0.0197	0.0202	0.0049
4	0.0204	0.0207	0.0147	0.0201	0.0147
5	0.0201	0.0206	0.0249	0.0199	0.0100
6	0.0208	0.0212	0.0192	0.0208	0.0000
7	0.0218	0.0216	0.0092	0.0216	0.0092
8	0.0224	0.0222	0.0089	0.0224	0.0000
9	0.0232	0.0231	0.0043	0.0232	0.0000
10	0.0238	0.0237	0.0042	0.0239	0.0042
11	0.0227	0.0230	0.0132	0.0232	0.0220
12	0.0223	0.0228	0.0224	0.0230	0.0314
13	0.0220	0.0223	0.0136	0.0227	0.0318
14	0.0218	0.0223	0.0229	0.0227	0.0413
15	0.0217	0.0224	0.0323	0.0227	0.0461
16	0.0226	0.0229	0.0133	0.0231	0.0221
17	0.0277	0.0276	0.0036	0.0263	0.0505
18	0.0297	0.0286	0.0370	0.0254	0.1448
19	0.0279	0.0269	0.0358	0.0265	0.0502
20	0.0252	0.0248	0.0159	0.0251	0.0040
21	0.0231	0.0237	0.0260	0.0238	0.0303
22	0.0227	0.0224	0.0132	0.0226	0.0044
23	0.0215	0.0217	0.0093	0.0216	0.0047
24	0.0211	0.0208	0.0142	0.0203	0.0379
Maksimum Error		0.0370		0.1448	
Minimum Error		0.0036		0.0000	
Average Error		0.0162		0.0245	


Dari tabel 4.20 perbandingan antara ELM dan ANN diatas dapat diketahui bahwa metode ELM memiliki keakuratan MSE dan MAPE *testing* yang lebih baik daripada ANN yaitu sebesar 1.99E-07 dan

1.58% untuk ELM sedangkan  $8.16 \times 10^{-7}$  dan 2.35% untuk ANN. MSE dan MAPE *training*, nilai MSE dan MAPE *training* ANN bernilai lebih baik dari ELM yaitu  $2.04 \times 10^{-5}$  dan 11.93% untuk ELM sedangkan ANN bernilai  $1.85 \times 10^{-5}$  dan 11.53%.

Perbandingan *training* maupun *testing time*, jelas dapat dilihat bahwa ELM jauh lebih cepat jika dibandingkan dengan ANN yaitu 0.0929 dan 0.0177 untuk ELM serta 3.2914 dan 2.2076 untuk ANN. Hal ini menunjukkan bahwa ELM memiliki waktu yang lebih cepat dalam mengenali pola suatu data dan menghasilkan output dari ANN.

Pada tabel 4.21 dapat dilihat data besar error dari setiap jam yang dihasilkan oleh peramalan menggunakan metode ELM maupun ANN yang dibandingkan dengan data aktual.

Dapat diamati bahwa error maksimum ELM sebesar 0.0370% yang terdapat pada pola harga jam 6 malam, sedangkan error minimum ELM sebesar 0.0036% berada pada harga pada jam 5 sore. untuk ANN error maksimum sebesar 0.1448% yang terjadi pada jam 6 sore dan error minimum sebesar 0.0000 pada jam 6, 8, dan 9 pagi. Sehingga dari tabel dapat dilihat bahwa error maksimum ELM lebih kecil dari error maksimum yang dimiliki oleh ANN. Minimum error antara ELM dan ANN bernilai 0.0036% dan 0.0000%, dan ELM memiliki error rata-rata yang lebih kecil dibandingkan ANN yaitu 0.0162% untuk ELM dan 0.0245% untuk ANN. Sehingga dapat dilihat bahwa ELM memiliki kemampuan meramal yang lebih baik dibandingkan dengan ANN karena memiliki kecepatan waktu dan error yang lebih kecil.



**Gambar 4.14** Grafik perbandingan data aktual, data ramalan ELM dan ANN untuk harga hari Minggu, 26 November 2017



Plot data hasil ramalan harga listrik dari Minggu dengan metode ELM yang dibandingkan dengan metode ANN disajikan pada gambar 4.14 dibawah. Dapat diketahui bahwa data ramalan yang dihasilkan oleh ELM (garis warna merah) memiliki hasil yang tidak jauh beda dengan hasil ramalan ANN (garis warna hijau). Hasil ramalan kedua metode ini hampir memiliki pola yang sama dengan data beban aktual (garis warna biru).

Gambar 4.14 adalah grafik hasil peramalan ELM yang dibandingkan dengan peramalan BP untuk peramalan harga listrik hari Minggu, 26 November 2017.

#### **4.2.8 Perbandingan Error Peramalan Menggunakan ELM dan BP**

Dari simulasi peramalan harga listrik secara keseluruhan dari hari senin hingga hari minggu dengan menggunakan ELM yang dibandingkan secara langsung dengan ANN, menunjukkan bahwa hasil peramalan dengan menggunakan ELM memiliki nilai yang lebih akurat dibandingkan dengan hasil peramalan ANN. Berikut tabel yang menyajikan hasil perbandingan error (%) peramalan harga mulai hari Senin sampai hari Minggu.

Dari tabel 4.22 dapat diketahui besar error yang dihasilkan oleh metode ELM dan ANN untuk peramalan ditiap harinya dari hari Senin hingga hari Minggu. Dapat diketahui bahwa hasil perbandingan kedua metode menunjukan bahwa ELM memiliki error maksimum bernilai 0.1409% pada hari senin dan error minimumnya 0% yang pernah terjadi pada hari Selasa, Kamis, dan Jumat. Sementara ANN memiliki error maksimum sebesar 0.1448% yang terjadi pada hari minggu dan memiliki nilai error maksimum sebesar 0% yang terjadi kecuali hari Senin. Dari tabel dapat disimpulkan bahwa error ELM dan ANN tidak jauh berbeda, dan masih dalam batas toleransi error sebesar 3% untuk peramalan. Error ini dapat dikurangi dengan cara menambahkan pengelompokan harga termasuk harga pada saat hari libur maupun harga saat kondisi-kondisi tertentu ketika penggunaan energi listrik oleh konsumen lebih banyak dari suplai oleh penyedia energi listrik, sehingga dapat terlihat pola yang lebih baik dan korelasi yang lebih besar.

Keunggulan dari ELM pada peramalan ini adalah waktu yang dibutuhkan oleh ELM untuk training maupun testing sangat cepat bila dibandingkan dengan ANN. Hal ini sangat dibutuhkan ketika kondisi sedang mengharuskan melakukan peramalan yang cepat dengan error yang kecil, sehingga sangat cocok ketika pengguna mengakses manajemen energi rumahnya dari jarak jauh menggunakan gadget yang dimilikinya.

Selain itu, cepatnya training time yang dimiliki oleh ELM dapat sebagai pertimbangan ketika memiliki data yang sangat banyak sebagai tuntutan batasan yang dapat menunjang keakuratan peramalan, karena hanya membutuhkan waktu yang sebentar dalam mengenali pola data yang akan diolah, karena jika menggunakan ANN akan memerlukan waktu yang lebih lama.

**Tabel 4.22** Perbandingan Error Peramalan Menggunakan ELM dan ANN.

Perbandingan Error Hasil Peramalan (%)			
Hari	Error	ELM	ANN
Senin	Maksimum	0.1409	0.1163
	Minimum	0.0004	0.0004
	Rata-Rata	0.0254	0.0304
Selasa	Maksimum	0.0393	0.0506
	Minimum	0.0000	0.0000
	Rata-Rata	0.0151	0.0216
Rabu	Maksimum	0.0737	0.0749
	Minimum	0.0008	0.0000
	Rata-Rata	0.0156	0.0214
Kamis	Maksimum	0.0766	0.0574
	Minimum	0.0000	0.0000
	Rata-Rata	0.0190	0.0215
Jumat	Maksimum	0.0469	0.0547
	Minimum	0.0000	0.0000
	Rata-Rata	0.0184	0.0210
Sabtu	Maksimum	0.0481	0.0519
	Minimum	0.0053	0.0000
	Rata-Rata	0.0248	0.0264
Minggu	Maksimum	0.0370	0.1448
	Minimum	0.0036	0.0000
	Rata-Rata	0.0162	0.0245

Dari tabel 4.23, dapat diketahui bahwa ELM memiliki *learning speed* yang sangat cepat jika dibandingkan dengan ANN. Waktu *training* tercepat sebesar 0.0854 detik yang terjadi pada hari Rabu dan waktu *testing* tersepat sebesar 0.0126 detik yang juga terjadi pada hari Rabu. Waktu *training* paling lama yang dibutuhkan ELM dalam mengolah data ini adalah sebesar 0.1081 detik yang terjadi pada hari Sabtu dan waktu *testing* terlama yang dibuthkan oleh ELM adalah 0.0177 detik yang terjadi pada hari minggu. Hal ini sangat berbeda jauh jika dibandingkan dengan ANN yang membutuhkan waktu *training* pada selang waktu 3 hingga 4 untuk setiap harinya dan waktu *testing* yang dibutuhkan oleh ANN diatas 2 detik.

**Tabel 4.23** Perbandingan training dan testing time ELM dan ANN


Perbandingan Waktu Peramalan (Detik)			
Hari	Waktu	ELM	ANN
Senin	Training	0.0950	3.3948
	Testing	0.0163	2.1563
Selasa	Training	0.0951	3.2381
	Testing	0.0161	2.3731
Rabu	Training	0.0854	3.2568
	Testing	0.0126	2.1803
Kamis	Training	0.0914	4.1157
	Testing	0.0154	2.4928
Jumat	Training	0.0881	3.1786
	Testing	0.0165	2.1966
Sabtu	Training	0.1081	3.2115
	Testing	0.0168	2.2323
Minggu	Training	0.0929	3.2914
	Testing	0.0177	2.2076

Dari keseluruhan peramalan ELM yang telah dilakukan mulai dari peramalah harga listrik pada hari Senin hingga Minggu yang dilakukan secara *trial and error* dengna fungsi aktivasi logsig, dan jumlah *hidden neuron* yang berbeda-beda dari 1 hingga 15, didapatkan hasil terbaik jika menggunakan 15 *hidden neuron* di mayoritas hari, kecuali pada hari Minggu yang menggunakan 5 *hidden neuron* bila

ingin mendapatkan eror terkecil. Hal ini karena mayoritas hari memiliki MSE dan MAPE terkecil pada hidden neuron tersebut yang dapat dilihat pada lampiran percobaan dengan menggunakan 15 *hidden neuron*, kecuali pada hari Minggu yang menggunakan 5 *hidden neuron*.

#### 4.2.9 Perbandingan Total Pemakaian Energi Listrik Dengan Peramalan ELM dan ANN, serta Tanpa Menggunakan Peramalan dan Penjadwalan Peralatan Rumah Tangga

Dalam manajemen energi, tujuan utamanya adalah memiliki tagihan listrik yang lebih murah jika tanpa menggunakan manajemen energi. Hal ini karena semakin berkembangnya teknologi, membuat segala aktivitas sehari-hari tidak lepas dari pemanfaatan peralatan elektronik yang sudah terbukti dapat menghemat waktu dan sangat membantu dalam memberikan kenyamanan.




**Gambar 4.15** Grafik Perbandingan Profil Peralatan Terjadwal.

Sehingga saat harga energi listrik telah menerapkan *real time pricing*, pengguna peralatan listrik harus mengetahui harga listrik termurah agar dapat memanfaatkan peralatan elektronik yang dimilikinya semaksimal mungkin dan mengetahui total tagihan diakhir bulan dari penggunaan listriknya. Selain itu, pengguna juga dapat menjadwalkan peralatan yang memiliki sifat harus dinyalakan seperti lampu ketika

mereka sedang diluar, karena smart switch secara otomatis akan melakukan perintah sesuai dengan penjadwalan beban yang dimasukkan oleh pengguna setelah mengetahui harga listrik yang akan datang.

Pada gambar 4.15 Terlihat profil peralatan yang digunakan sehari-hari tanpa terjadwal. Terlihat pengguna masih banyak menggunakan peralatannya di saat jam beban puncak yaitu 6 malam hingga jam 8 malam. Ada beban yang dapat dijadwalkan dan dioperasikan tidak pada jam beban puncak atau saat harga listrik rendah, sehingga perlunya penjadwalan yang dilakukan oleh pengguna. Pada gambar 4.16 dapat terlihat bahwa pengguna telah mengurangi penggunaan peralatan diwaktu beban puncak, sehingga pada akhir nanti pengguna akan mendapatka keuntungan dari penjadwalan peralatan yaitu berkurangnya tagihan listrik.



**Gambar 4.16** Grafik Perbandingan Profil Peralatan Terjadwal


Tidak dapat dipungkiri bahwa pengguna tidak dapat benar2 tidak menggunakan peralatannya pada jam-jam tertentu, karena peralatan memiliki sifat kinerja yang berbeda-beda dan juga terdapat faktor kenyamanan yang memang haya pengguna sendiri yang dapat menjadwalkannya.

Tabel 4.28 berisi perbandingan penggunaan energi listrik ketika pengguna memiliki alat peramalan menggunakan metode ELM dan -

**Tabel 4.24** Perbandingan Manfaat Menggunakan Penjadwalan Beban pada model harga listrik yang berbeda.

Model Pricing	Tagihan Tanpa Penjadwalan (\$)	Tagihan Dengan Penjadwalan (\$)	Total Keuntungan (\$)
RTP	3.8945	3.6867	0.2078
Peramalan ELM	3.9350	3.7332	0.2018
Peramalan ANN	3.9268	3.7376	0.1892
IBR dengan RTP	8.7945	6.4657	2.3289


ANN dibandingkan pengguna tanpa memiliki peramalan serta perbandingan antara pengguna yang menggunakan penjadwalan peralatan dengan yang tidak menggunakan fitur penjadwalan peralatan.



**Gambar 4.17** Grafik Perbandingan Profil Peralatan Terjadwal

Dari tabel 4.24 dapat terlihat bahawa sangat terlihat perbedaan harga tanpa penjadwalan dengan tagihan yang telah menggunakan penjadwalan peralatan listrik, memiliki selisih dan tentunya sangat menguntungkan untuk pemilik rumah ketika membayar tagihan listrik diakhir bulan. Ketika menggunakan model RTP, tagihan yang akan dikenakan pada pengguna yaitu sebesar 3.8945 dollar dalam

seminggu. Tetapi ketika menggunakan penjadwalan peralatan listrik, pengguna akan memiliki tagihan sebesar 3.6867 dollar. Sehingga pengguna akan mendapat penghematan tagihan yaitu sebesar 0.2078 dollar.



**Gambar 4.18** Grafik Perbandingan Total Tagihan Energi Listrik.

Sedangkan ketika harga menggunakan ramalan dari ELM, tagihan yang akan dikenakan pada pengguna yaitu sebesar 3.9350 dollar dalam seminggu. Tetapi ketika menggunakan penjadwalan peralatan listrik, pengguna akan memiliki tagihan sebesar 3.7332 dollar. Sehingga pengguna akan mendapat penghematan tagihan yaitu sebesar 0.2018 dollar. Begitu juga saat menggunakan ramalan dari ANN, tagihan yang akan dikenakan pada pengguna yaitu sebesar 3.9268 dollar dalam seminggu.

Saat menggunakan penjadwalan peralatan listrik, pengguna akan memiliki tagihan sebesar 3.7376 dollar. Sehingga pengguna akan mendapat penghematan tagihan yaitu sebesar 0.1892 dollar. Namun sedikit berbeda saat menggunakan model IBR yang dikombinasikan dengan RTP. Tarif IBR akan otomatis dikenakan pada pelanggan ketika jam beban puncak, sehingga pelanggan harus dituntut lebih bijak dalam menjadwalkan penggunaan peralatan elektronik yang dimiliki. tagihan yang akan dikenakan pada pengguna yaitu sebesar 8.7945 dollar dalam seminggu. Saat menggunakan penjadwalan

peralatan listrik, pengguna akan memiliki tagihan sebesar 6.4657 dollar. Sehingga pengguna akan mendapat penghematan tagihan yaitu sebesar 0. 2.3289 dollar. Hal ini sangat terlihat selisih penghematan yang akan dirasakan oleh pengguna jika menggunakan penjadwalan dalam menggunakan peralatan yang dimiliki.

Gambar 4.17 menunjukkan perbandingan grafik antara menggunakan penjadwalan dengan yang tidak menggunakan penjadwalan dalam menggunakan peralatan.

Pada gambar 4.18 dapat terlihat selisih yang dihasilkan ketika pengguna menggunakan penjadwalan dalam penggunaan peralatan yang dimiliki yang selanjutnya selisih tersebut menjadi keuntungan yang akan dimiliki oleh pengguna.



## **BAB V**

### **PENUTUP**

#### **5.1 Kesimpulan**

Pada tugas akhir yang telah saya lakukan, dapat ditarik kesimpulan yaitu:

1. Peramalan Harga listrik dengan menggunakan *Extreme Learning Machine* (ELM) mampu menghasilkan prediksi dengan error rata-rata minimum sebesar 0.0015% dengan error rata-rata maksimum sebesar 0.0661%
2. ELM memiliki learning speed yang cepat dengan waktu minimum 0.0854 detik dan maksimum 0.1081 detik. Sedangkan learning speed ANN memiliki waktu minimum 3.1786 detik dan waktu maksimum 4.1157 hal ini sangat menguntungkan ELM karena peramalan membutuhkan learning speed yang cepat
3. Berdasarkan uji coba, fungsi aktivasi logsig dengan hidden neuron yang paling sesuai dengan seluruh hari kecuali hari minggu adalah 5 *hidden neuron*. Hal ini karena dapat menghasilkan nilai error MSE dan MAPE terkecil dibanding dengan jumlah hidden neuron yang lain.
4. Algoritma ELM lebih sederhana dan cenderung memperoleh error yang kecil.
5. Output dari ELM ditentukan oleh jumlah *hidden neuron* dan fungsi aktivasi.
6. Model *real-time pricing* memiliki banyak keuntungan untuk pengguna dalam skala rumah tangga, tetapi pengguna harus siap memiliki peralatan untuk penjadwalan secara otomatis dan juga peralatan untuk meramalkan harga listrik yang akan datang
7. IBR dan RTP dapat memaksa pengguna untuk menggunakan penjadwalan peralatan agar lebih menguntungkan dan lebih hemat.

8. Dengan penjadwalan pemakaian energi listrik ketika penyedia listrik menerapkan konsep power market, dapat menguntungkan pengguna skala rumah tangga.

## **5.2 Saran**

1. Menggolongkan harga listrik sesuai dengan kejadian pada hari tersebut seperti hari besar maupun kejadian besar seperti piala dunia.
2. Mencoba menggunakan fungsi aktivasi lainnya untuk melakukan peramalan dengan ELM.
3. Menggunakan algoritma optimasi dalam melakukan penjadwalan.

## DAFTAR PUSTAKA

- [1] S. Althaher, P. Mancarella, and J. Mutale, "Automated Demand Response From Home Energy Management System Under Dynamic Pricing and Power and Comfort Constraints," *IEEE Transactions on Smart Grid*, vol. 6, pp. 1874-1883, 2015.
- [2] M. A. A. Pedrasa, T. D. Spooner, and I. F. MacGill, "Coordinated Scheduling of Residential Distributed Energy Resources to Optimize Smart Home Energy Services," *IEEE Transactions on Smart Grid*, vol. 1, pp. 134-143, 2010.
- [3] Q. Tang, K. Yang, D. Zhou, Y. Luo, and F. Yu, "A Real-Time Dynamic Pricing Algorithm for Smart Grid With Unstable Energy Providers and Malicious Users," *IEEE Internet of Things Journal*, vol. 3, pp. 554-562, 2016.
- [4] M. Pipattanasomporn, M. Kuzlu, and S. Rahman, "An Algorithm for Intelligent Home Energy Management and Demand Response Analysis," *IEEE Transactions on Smart Grid*, vol. 3, pp. 2166-2173, 2012.
- [5] R. Krishnan, "Meters of tomorrow," *IEEE Power Energy Mag.*, vol. 6, no. 2, pp. 92-94, Mar. 2008.
- [6] U.S. Dept. Energy, The smart grid: An introduction 2009 [Online]. Available: <http://www.oe.energy.gov/SmartGridIntroduction.htm>
- [7] A. Vojdani, "Smart integration," *IEEE Power Energy Mag.*, vol. 6, no. 6, pp. 72-79, Nov. 2008.
- [8] L. H. Tsoukalas and R. Gao, "From smart grids to an energy Internet: Assumptions, architectures, and requirements," in *Proc. 3rd Int. Conf. Electric Utility Deregulation and Restructuring and Power Technol.*, Apr. 2008, pp. 94-98.
- [9] S. Pal and R. Kumar, "Effective load scheduling of residential consumers based on dynamic pricing with price prediction capabilities," 2016 IEEE 1<sup>st</sup> International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES), Delhi, 2016, pp. 1-6.
- [10] J. S. Vardakas, N. Zorba, and C. V. Verikoukis, "A Survey on Demand Response Programs in Smart Grids: Pricing Methods and Optimization Algorithms," *IEEE*

- Communications Surveys & Tutorials, vol. 17, pp. 152-178, 2015.
- [11] B. C. Hydro, "Residential Rates. [Online]. Available: <https://www.bchydro.com/accounts-billing/bill-payment/bill-details/bill-details-residential.html>," November 10, 2017.
  - [12] P. Reiss and M. White, "Household electricity demand, revisited," *Rev. Econ. Studies*, vol. 72, no. 3, pp. 853–883, July 2005.
  - [13] A. H. Mohsenian-Rad, V. Wong, J. Jatskevich, and R. Schober, "Optimal and autonomous incentive-based energy consumption scheduling algorithm for smart grid," presented at the IEEE PES Conf. Innov.
  - [14] S. Borenstein, The long-run effects of real-time electricity pricing, Center for the Study of Energy Markets, Working Paper 133, 2004.
  - [15] F. Wolak, Residential customer response to real-time pricing: The Anaheim critical peak pricing experiment, Center for the Study of Energy Markets, Working Paper 151, May 2006.
  - [16] W. Burke and D. Auslander, "Residential electricity auction with uniform pricing and cost constraints," presented at the North Amer. Power Symp., Starkville, MS, Oct. 2009.
  - [17] P. Centolella, "The integration of price responsive demand into regional transmission organization (RTO) wholesale power markets and system operations," *Energy*, to be published.
  - [18] B. Alexander, Smart meters, real time pricing, and demand response programs: Implications for low income electric customers Oak Ridge Natl. Lab., Tech. Rep., Feb. 2007.
  - [19] S. Holland and E. Mansur, "Is real-time pricing green? The environmental impacts of electricity demand variance," *Rev. Econ. Stat.*, vol. 90, no. 3, pp. 550–561, Aug. 2008.
  - [20] A. I. Corporation, "Real-Time Pricing for Residential Customers. [Online]. Available: <https://www.ameren.com/illinois/electric-choice/residential-real-time-pricing>," November 10, 2017.
  - [21] Makridakis, S., S. Wheelwright., dan VE McGee. 1999. *Metode dan Aplikasi Peramalan*. Edisi kedua. Jilid satu. Jakarta: Binarupa Aksara.

- [22] R. E. Uhrig, "Introduction to artificial neural networks," Industrial Electronics, Control, and Instrumentation, 1995., Proceedings of the 1995 IEEE IECON 21st International Conference on, Orlando, FL, 1995, pp. 33-37 vol.1.
- [23] Mitchel, T.M. 1997. Machine Learning. Singapore: McGraw-Hill.
- [24] Zhang, Peter & Patuwo, Eddy & Hu, Michael. (1998). Forecasting With Artificial Neural Networks: The State of the Art. International Journal of Forecasting. 14. 35-62.
- [25] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, "Extreme learning machine: Theory and applications," Neurocomputing, vol. 70, pp. 489-501, 2006.
- [26] A. Makarenko, "Toward development of neural networks with strong anticipation," 2017 IEEE First Ukraine Conference on Electrical and Computer Engineering (UKRCON), Kiev, 2017, pp. 1084-1087.
- [27] X. Yang et al., "A forecasting method of air conditioning energy consumption based on extreme learning machine algorithm," 2017 6th Data Driven Control and Learning Systems (DDCLS), Chongqing, 2017, pp. 89-93.
- [28] H. Allcott, Real time pricing and electricity markets, Working Paper, Harvard Univ., Feb. 2009.
- [29] A. Ipakchi and F. Albuyeh, "Grid of the future," IEEE Power Energy. Mag., vol. 8, no. 4, pp. 52–62, Mar. 2009.
- [30] Office of Energy Efficiency, Natural Resources Canada, Energy consumption of major household appliances shipped in Canada 2005 [Online]. Available: "<http://oee.nrcan.gc.ca>" Januari 31, 2018.
- [31] M. A. A. Pedrasa, T. D. Spooner, and I. F. MacGill, "Coordinated Scheduling of Residential Distributed Energy Resources to Optimize Smart Home Energy Services," IEEE Transactions on Smart Grid, vol. 1, pp. 134-143, 2010.
- [32] ZigBee Alliance, Zigbee smart energy profile specification, Zigbee. Doc. 075356r15, rev. 15, Dec. 2008.

- [33] ZigBee Plus HomePlug Joint Working Group, Smart energy profile marketing requirements document, Draft rev. 1.0, Mar. 2009.
- [34] G. A. McNaughton and R. Saint, "Enterprise integration implications for home-area network technologies," presented at the IEEE PES Conf. Innov. Smart Grid Technol., Gaithersburg, MD, Jan. 2010.
- [35] Demuth, H., Beale, M.2000. Neural Network Toolbox For Use with MATLAB. Massachusetts: The Math Work Inc.
- [36] Guang-Bin Huang, Qin-Yu Zhu and Chee-Kheong Siew, "Extreme learning machine: a new learning scheme of feedforward neural networks," 2004 IEEE International Joint Conference on Neural Networks (IEEE Cat. No.04CH37541), 2004, pp. 985-990 vol.2.

## LAMPIRAN

### Lampiran 1. Trial and Error hari Senin (\$)

Hasil Trial Prediksi Hari Senin, 18 Desember 2017 (\$)						
Jam	Hidden neuron					
	1	2	3	4	5	6
1	0.0235	0.0234	0.0206	0.0226	0.0205	0.0225
2	0.0235	0.0234	0.0206	0.0211	0.0205	0.0213
3	0.0235	0.0234	0.0207	0.0203	0.0206	0.0205
4	0.0235	0.0234	0.0207	0.0201	0.0207	0.0203
5	0.0235	0.0234	0.0217	0.0211	0.0218	0.0214
6	0.0236	0.0235	0.0251	0.0234	0.0251	0.0234
7	0.0236	0.0235	0.0279	0.0258	0.0277	0.0258
8	0.0236	0.0234	0.0264	0.0289	0.0261	0.0285
9	0.0235	0.0233	0.0263	0.0317	0.0262	0.0310
10	0.0235	0.0233	0.0254	0.0349	0.0255	0.0343
11	0.0235	0.0233	0.0240	0.0378	0.0242	0.0373
12	0.0234	0.0232	0.0233	0.0412	0.0234	0.0411
13	0.0234	0.0232	0.0224	0.0440	0.0225	0.0447
14	0.0234	0.0232	0.0223	0.0475	0.0224	0.0492
15	0.0234	0.0232	0.0220	0.0492	0.0220	0.0520
16	0.0234	0.0232	0.0222	0.0515	0.0222	0.0554
17	0.0235	0.0233	0.0258	0.0516	0.0258	0.0557
18	0.0235	0.0232	0.0272	0.0486	0.0270	0.0508
19	0.0235	0.0232	0.0259	0.0441	0.0258	0.0445
20	0.0235	0.0232	0.0242	0.0408	0.0243	0.0407
21	0.0235	0.0233	0.0227	0.0381	0.0229	0.0377
22	0.0234	0.0233	0.0218	0.0314	0.0217	0.0313
23	0.0234	0.0233	0.0210	0.0280	0.0206	0.0284
24	0.0234	0.0233	0.0202	0.0258	0.0198	0.0261

Lanjutan lampiran 1. Trial and Error hari Senin (\$)

Hasil Trial Prediksi Hari Senin, 18 Desember 2017 (\$)					
Jam	Hidden neuron				
	7	8	9	10	15
1	0.0202	0.0205	0.0203	0.0204	0.0199
2	0.0203	0.0205	0.0203	0.0204	0.0199
3	0.0204	0.0205	0.0204	0.0204	0.0200
4	0.0204	0.0206	0.0205	0.0205	0.0201
5	0.0213	0.0217	0.0216	0.0219	0.0216
6	0.0257	0.0250	0.0250	0.0248	0.0255
7	0.0286	0.0280	0.0283	0.0286	0.0291
8	0.0268	0.0265	0.0261	0.0263	0.0267
9	0.0262	0.0265	0.0258	0.0264	0.0262
10	0.0254	0.0257	0.0252	0.0255	0.0253
11	0.0241	0.0242	0.0243	0.0242	0.0241
12	0.0233	0.0233	0.0236	0.0234	0.0235
13	0.0225	0.0225	0.0227	0.0226	0.0228
14	0.0224	0.0224	0.0226	0.0225	0.0227
15	0.0221	0.0220	0.0222	0.0221	0.0223
16	0.0223	0.0223	0.0225	0.0224	0.0226
17	0.0256	0.0259	0.0253	0.0257	0.0254
18	0.0266	0.0275	0.0261	0.0273	0.0267
19	0.0255	0.0260	0.0254	0.0257	0.0254
20	0.0242	0.0243	0.0244	0.0243	0.0242
21	0.0231	0.0229	0.0232	0.0231	0.0231
22	0.0219	0.0218	0.0219	0.0219	0.0221
23	0.0209	0.0208	0.0206	0.0207	0.0209
24	0.0203	0.0198	0.0196	0.0201	0.0194



**Lanjutan lampiran 1. Nilai MSE, MAPE, Time**

Hidden neuron	MSE		MAPE		Time Sec	
	Training	Testing	Training	Testing	Training	Testing
1	7.60E-05	8.59E-06	24.25	10.89	0.0942	0.0162
2	7.64E-05	8.70E-06	23.67	10.78	0.0990	0.0193
3	4.03E-05	9.78E-07	14.34	3.44	0.1064	0.0157
4	4.02E-05	9.78E-07	14.16	3.33	0.0852	0.0116
5	3.95E-05	9.42E-07	14.07	3.29	0.0898	0.0118
6	3.98E-05	1.02E-06	14.11	3.21	0.0868	0.0121
7	3.95E-05	1.09E-06	14.31	3.17	0.0929	0.0160
8	3.99E-05	7.96E-07	14.18	3.10	0.0862	0.0115
9	3.89E-05	9.90E-07	14.03	3.09	0.0930	0.0187
10	3.87E-05	7.80E-07	14.01	3.01	0.0931	0.0157
15	3.86E-05	9.20E-07	14.07	2.54	0.0950	0.0163

**Lampiran 2. MSE, MAPE, Time**

Hidden neuron	MSE		MAPE		Time Sec	
	Training	Testing	Training	Testing	Training	Testing
1	6.49E-05	3.60E-05	22.60	21.37	0.0932	0.0122
2	4.99E-05	1.52E-05	18.35	14.02	0.0894	0.0120
3	2.92E-05	3.34E-06	12.46	4.99	0.0928	0.0163
4	2.47E-05	8.46E-07	11.50	3.52	0.0870	0.0124
5	2.16E-05	7.35E-07	10.74	2.96	0.0859	0.0126
6	2.25E-05	6.88E-07	10.91	2.77	0.0905	0.0178
7	2.19E-05	5.05E-07	10.70	2.48	0.0907	0.0176
8	2.11E-05	3.45E-07	10.52	2.25	0.0914	0.0163
9	2.14E-05	3.66E-07	10.51	2.13	0.0919	0.0161
10	2.12E-05	3.29E-07	10.60	2.05	0.0922	0.0170
15	2.05E-05	1.77E-07	10.42	1.54	0.0951	0.0161

Lanjutan lampiran 2. Trial and Error hari Selasa (\$)

Hasil Trial Prediksi Hari Selasa, 8 Agustus 2017 (\$)						
Jam	Hidden neuron					
	1	2	3	4	5	6
1	0.0258	0.0236	0.0206	0.0206	0.0203	0.0200
2	0.0258	0.0227	0.0200	0.0198	0.0198	0.0197
3	0.0258	0.0226	0.0196	0.0195	0.0195	0.0195
4	0.0258	0.0226	0.0196	0.0194	0.0194	0.0194
5	0.0258	0.0231	0.0198	0.0198	0.0197	0.0196
6	0.0258	0.0237	0.0208	0.0208	0.0205	0.0202
7	0.0258	0.0244	0.0217	0.0217	0.0212	0.0209
8	0.0258	0.0246	0.0228	0.0227	0.0221	0.0219
9	0.0258	0.0249	0.0237	0.0235	0.0230	0.0229
10	0.0258	0.0256	0.0257	0.0247	0.0242	0.0243
11	0.0258	0.0258	0.0271	0.0260	0.0258	0.0260
12	0.0258	0.0263	0.0289	0.0278	0.0280	0.0283
13	0.0258	0.0272	0.0296	0.0297	0.0301	0.0303
14	0.0258	0.0275	0.0312	0.0321	0.0331	0.0331
15	0.0258	0.0283	0.0320	0.0340	0.0353	0.0350
16	0.0258	0.0298	0.0322	0.0359	0.0375	0.0363
17	0.0258	0.0304	0.0318	0.0362	0.0374	0.0361
18	0.0258	0.0289	0.0312	0.0335	0.0341	0.0340
19	0.0258	0.0274	0.0299	0.0301	0.0304	0.0307
20	0.0258	0.0263	0.0286	0.0279	0.0281	0.0283
21	0.0258	0.0268	0.0275	0.0269	0.0264	0.0269
22	0.0258	0.0251	0.0242	0.0240	0.0236	0.0236
23	0.0258	0.0254	0.0228	0.0231	0.0222	0.0222
24	0.0258	0.0248	0.0217	0.0221	0.0213	0.0211

Lanjutan lampiran 2. Trial and Error hari Selasa (\$)

Hasil Trial Prediksi Hari Selasa, 8 Agustus 2017 (\$)					
Jam	Hidden neuron				
	7	8	9	10	15
1	0.0199	0.0200	0.0199	0.0199	0.0196
2	0.0195	0.0192	0.0194	0.0193	0.0189
3	0.0193	0.0188	0.0191	0.0190	0.0186
4	0.0192	0.0187	0.0189	0.0188	0.0185
5	0.0194	0.0191	0.0192	0.0191	0.0188
6	0.0201	0.0203	0.0200	0.0201	0.0198
7	0.0208	0.0213	0.0209	0.0210	0.0208
8	0.0219	0.0225	0.0220	0.0224	0.0221
9	0.0229	0.0234	0.0230	0.0234	0.0232
10	0.0243	0.0247	0.0245	0.0249	0.0248
11	0.0260	0.0261	0.0261	0.0263	0.0265
12	0.0283	0.0280	0.0282	0.0283	0.0284
13	0.0301	0.0298	0.0299	0.0299	0.0298
14	0.0328	0.0326	0.0326	0.0327	0.0324
15	0.0348	0.0346	0.0347	0.0348	0.0346
16	0.0365	0.0364	0.0366	0.0367	0.0368
17	0.0362	0.0364	0.0364	0.0366	0.0367
18	0.0336	0.0335	0.0335	0.0337	0.0334
19	0.0304	0.0301	0.0302	0.0303	0.0302
20	0.0283	0.0281	0.0282	0.0282	0.0284
21	0.0268	0.0266	0.0268	0.0269	0.0271
22	0.0236	0.0240	0.0237	0.0241	0.0241
23	0.0221	0.0226	0.0221	0.0224	0.0224
24	0.0210	0.0215	0.0210	0.0212	0.0211

### Lampiran 3. Trial and Error hari Rabu (\$)

Hasil Trial Prediksi Hari Rabu, 9 Agustus 2017 (\$)						
Jam	Hidden neuron					
	1	2	3	4	5	6
1	0.0259	0.0256	0.0222	0.0196	0.0196	0.0193
2	0.0259	0.0255	0.0219	0.0192	0.0193	0.0188
3	0.0259	0.0255	0.0217	0.0191	0.0191	0.0185
4	0.0259	0.0254	0.0216	0.0190	0.0190	0.0184
5	0.0259	0.0257	0.0221	0.0192	0.0192	0.0189
6	0.0260	0.0260	0.0230	0.0194	0.0197	0.0196
7	0.0260	0.0261	0.0235	0.0198	0.0202	0.0204
8	0.0260	0.0259	0.0238	0.0207	0.0212	0.0214
9	0.0260	0.0260	0.0244	0.0215	0.0222	0.0224
10	0.0261	0.0263	0.0256	0.0231	0.0237	0.0241
11	0.0261	0.0261	0.0261	0.0254	0.0255	0.0259
12	0.0261	0.0259	0.0264	0.0278	0.0274	0.0277
13	0.0262	0.0261	0.0278	0.0299	0.0302	0.0303
14	0.0263	0.0266	0.0299	0.0312	0.0335	0.0331
15	0.0264	0.0268	0.0310	0.0319	0.0354	0.0348
16	0.0265	0.0269	0.0322	0.0324	0.0374	0.0368
17	0.0264	0.0264	0.0309	0.0330	0.0368	0.0364
18	0.0262	0.0256	0.0275	0.0327	0.0332	0.0329
19	0.0262	0.0257	0.0266	0.0311	0.0304	0.0303
20	0.0261	0.0254	0.0252	0.0287	0.0276	0.0276
21	0.0261	0.0257	0.0252	0.0269	0.0261	0.0263
22	0.0260	0.0256	0.0237	0.0233	0.0230	0.0232
23	0.0260	0.0256	0.0231	0.0215	0.0214	0.0216
24	0.0259	0.0255	0.0224	0.0208	0.0203	0.0204

Lanjutan lampiran 3. Trial and Error hari Rabu (\$)

Hasil Trial Prediksi Hari Rabu, 9 Agustus (\$)					
Jam	Hidden neuron				
	7	8	9	10	15
1	0.0190	0.0192	0.0189	0.0190	0.0190
2	0.0183	0.0187	0.0184	0.0183	0.0184
3	0.0179	0.0184	0.0181	0.0180	0.0181
4	0.0177	0.0182	0.0180	0.0178	0.0179
5	0.0185	0.0188	0.0184	0.0183	0.0185
6	0.0194	0.0196	0.0193	0.0192	0.0193
7	0.0203	0.0203	0.0201	0.0201	0.0202
8	0.0215	0.0213	0.0215	0.0215	0.0214
9	0.0227	0.0224	0.0227	0.0227	0.0226
10	0.0245	0.0242	0.0247	0.0246	0.0246
11	0.0261	0.0259	0.0264	0.0263	0.0263
12	0.0277	0.0277	0.0280	0.0278	0.0278
13	0.0300	0.0301	0.0304	0.0300	0.0302
14	0.0327	0.0327	0.0330	0.0326	0.0328
15	0.0345	0.0342	0.0346	0.0342	0.0345
16	0.0369	0.0362	0.0365	0.0363	0.0366
17	0.0366	0.0360	0.0362	0.0359	0.0365
18	0.0326	0.0327	0.0328	0.0318	0.0325
19	0.0299	0.0302	0.0304	0.0297	0.0300
20	0.0275	0.0276	0.0279	0.0274	0.0275
21	0.0262	0.0262	0.0265	0.0264	0.0263
22	0.0233	0.0230	0.0233	0.0234	0.0233
23	0.0217	0.0213	0.0215	0.0217	0.0216
24	0.0205	0.0202	0.0200	0.0204	0.0203

**Lanjutan lampiran 3. MSE, MAPE, Time**

Hidden neuron	MSE		MAPE		Time Sec	
	Training	Testing	Training	Testing	Training	Testing
1	6.89E-05	3.85E-05	24.33	23.39	0.1004	0.0126
2	6.53E-05	3.69E-05	23.48	23.01	0.0869	0.0131
3	4.27E-05	1.10E-05	16.92	12.62	0.0934	0.0160
4	3.20E-05	3.11E-06	12.83	5.18	0.0967	0.0151
5	2.37E-05	8.44E-07	11.39	3.15	0.0926	0.0181
6	2.14E-05	4.52E-07	10.77	2.31	0.0915	0.0152
7	2.10E-05	2.21E-07	10.77	1.57	0.0934	0.0172
8	2.10E-05	4.64E-07	10.76	2.36	0.1068	0.0152
9	2.13E-05	2.76E-07	10.94	1.84	0.0906	0.0167
10	2.12E-05	2.78E-07	10.88	1.73	0.0945	0.0166
15	2.11E-05	2.30E-07	10.80	1.56	0.0854	0.0126

**Lampiran 4. MSE, MAPE, Time**

Hidden neuron	MSE		MAPE		Time Sec	
	Training	Testing	Training	Testing	Training	Testing
1	7.26E-05	7.29E-05	23.32	30.23	0.1141	0.0119
2	6.82E-05	5.73E-05	22.96	27.39	0.1086	0.0168
3	5.62E-05	3.35E-05	17.66	19.56	0.1046	0.0153
4	3.71E-05	7.27E-06	14.08	8.85	0.1049	0.0156
5	3.51E-05	4.15E-06	12.85	6.81	0.1080	0.0154
6	2.89E-05	1.75E-06	11.32	3.34	0.1054	0.0155
7	2.84E-05	1.03E-06	11.27	3.19	0.1053	0.0153
8	2.83E-05	9.36E-07	11.21	2.81	0.1056	0.0155
9	2.81E-05	8.68E-07	11.09	2.78	0.1090	0.0161
10	2.73E-05	5.40E-07	11.04	2.17	0.0911	0.0158
15	2.55E-05	3.69E-07	10.88	1.86	0.0914	0.0154

Lanjutan lampiran 4. Trial and Error hari Kamis (\$)

Hasil Trial Prediksi Hari Kamis, 29 Juni 2017 (\$)						
Jam	Hidden neuron					
	1	2	3	4	5	6
1	0.0292	0.0284	0.0251	0.0219	0.0208	0.0194
2	0.0291	0.0284	0.0249	0.0222	0.0209	0.0185
3	0.0291	0.0284	0.0246	0.0224	0.0211	0.0178
4	0.0291	0.0283	0.0246	0.0223	0.0210	0.0178
5	0.0291	0.0282	0.0249	0.0221	0.0208	0.0185
6	0.0292	0.0280	0.0256	0.0216	0.0207	0.0202
7	0.0293	0.0282	0.0262	0.0218	0.0218	0.0221
8	0.0294	0.0285	0.0265	0.0229	0.0236	0.0239
9	0.0294	0.0290	0.0270	0.0245	0.0255	0.0255
10	0.0295	0.0297	0.0264	0.0271	0.0275	0.0269
11	0.0295	0.0303	0.0273	0.0307	0.0303	0.0293
12	0.0297	0.0299	0.0296	0.0342	0.0330	0.0320
13	0.0297	0.0309	0.0303	0.0367	0.0357	0.0343
14	0.0298	0.0315	0.0316	0.0385	0.0379	0.0373
15	0.0299	0.0317	0.0336	0.0389	0.0395	0.0395
16	0.0299	0.0320	0.0343	0.0392	0.0401	0.0408
17	0.0299	0.0320	0.0334	0.0391	0.0398	0.0399
18	0.0298	0.0318	0.0318	0.0388	0.0386	0.0380
19	0.0297	0.0310	0.0307	0.0370	0.0363	0.0349
20	0.0296	0.0300	0.0294	0.0338	0.0329	0.0317
21	0.0296	0.0303	0.0276	0.0323	0.0311	0.0302
22	0.0295	0.0299	0.0264	0.0269	0.0274	0.0269
23	0.0293	0.0298	0.0262	0.0239	0.0239	0.0247
24	0.0292	0.0287	0.0261	0.0220	0.0217	0.0221

Lanjutan lampiran 4. Trial and Error hari Kamis (\$)

Hasil Trial Prediksi Hari Kamis, 29 Juni 2017 (\$)					
Jam	Hidden neuron				
	7	8	9	10	15
1	0.0197	0.0192	0.0195	0.0190	0.0190
2	0.0189	0.0181	0.0186	0.0180	0.0178
3	0.0183	0.0174	0.0180	0.0171	0.0169
4	0.0184	0.0175	0.0181	0.0172	0.0170
5	0.0190	0.0183	0.0187	0.0180	0.0179
6	0.0205	0.0202	0.0202	0.0201	0.0202
7	0.0222	0.0224	0.0220	0.0223	0.0225
8	0.0238	0.0244	0.0237	0.0242	0.0244
9	0.0254	0.0261	0.0253	0.0258	0.0259
10	0.0266	0.0274	0.0265	0.0270	0.0269
11	0.0290	0.0296	0.0290	0.0296	0.0291
12	0.0323	0.0322	0.0322	0.0332	0.0321
13	0.0346	0.0344	0.0346	0.0356	0.0348
14	0.0378	0.0379	0.0379	0.0388	0.0387
15	0.0406	0.0407	0.0406	0.0414	0.0413
16	0.0423	0.0424	0.0422	0.0430	0.0430
17	0.0411	0.0413	0.0411	0.0419	0.0420
18	0.0386	0.0388	0.0388	0.0395	0.0396
19	0.0352	0.0350	0.0353	0.0362	0.0355
20	0.0319	0.0319	0.0319	0.0328	0.0318
21	0.0302	0.0304	0.0301	0.0308	0.0301
22	0.0264	0.0273	0.0264	0.0268	0.0268
23	0.0243	0.0249	0.0241	0.0244	0.0247
24	0.0221	0.0222	0.0219	0.0220	0.0222



### Lampiran 5. Trial and Error hari Jumat (\$)

Hasil Trial Prediksi Hari Jumat, 30 Juni 2017 (\$)						
Jam	Hidden neuron					
	1	2	3	4	5	6
1	0.0298	0.0268	0.0236	0.0214	0.0222	0.0217
2	0.0297	0.0255	0.0235	0.0207	0.0225	0.0210
3	0.0297	0.0257	0.0226	0.0197	0.0219	0.0205
4	0.0297	0.0260	0.0224	0.0196	0.0217	0.0205
5	0.0298	0.0270	0.0228	0.0203	0.0215	0.0211
6	0.0300	0.0286	0.0237	0.0221	0.0219	0.0222
7	0.0302	0.0289	0.0251	0.0246	0.0234	0.0239
8	0.0303	0.0292	0.0265	0.0259	0.0247	0.0251
9	0.0305	0.0297	0.0277	0.0278	0.0262	0.0266
10	0.0306	0.0301	0.0289	0.0296	0.0281	0.0285
11	0.0308	0.0308	0.0308	0.0321	0.0310	0.0314
12	0.0310	0.0306	0.0337	0.0355	0.0345	0.0349
13	0.0312	0.0317	0.0358	0.0373	0.0373	0.0378
14	0.0313	0.0323	0.0378	0.0394	0.0402	0.0407
15	0.0313	0.0328	0.0383	0.0396	0.0416	0.0420
16	0.0313	0.0325	0.0389	0.0405	0.0425	0.0423
17	0.0313	0.0329	0.0367	0.0380	0.0410	0.0411
18	0.0312	0.0321	0.0354	0.0374	0.0384	0.0387
19	0.0310	0.0308	0.0324	0.0349	0.0338	0.0343
20	0.0308	0.0304	0.0300	0.0315	0.0300	0.0304
21	0.0307	0.0308	0.0284	0.0299	0.0283	0.0288
22	0.0304	0.0295	0.0271	0.0277	0.0259	0.0264
23	0.0301	0.0285	0.0246	0.0256	0.0237	0.0242
24	0.0299	0.0280	0.0232	0.0232	0.0222	0.0225

Lanjutan lampiran 5. Trial and Error hari Jumat (\$)

Hasil Trial Prediksi Hari Jumat, 30 Juni 2017 (\$)					
Jam	Hidden neuron				
	7	8	9	10	15
1	0.0207	0.0213	0.0216	0.0213	0.0213
2	0.0193	0.0206	0.0210	0.0203	0.0206
3	0.0183	0.0199	0.0203	0.0197	0.0193
4	0.0183	0.0198	0.0202	0.0197	0.0191
5	0.0198	0.0205	0.0209	0.0205	0.0201
6	0.0221	0.0218	0.0223	0.0220	0.0220
7	0.0240	0.0239	0.0241	0.0242	0.0242
8	0.0256	0.0254	0.0254	0.0258	0.0257
9	0.0272	0.0272	0.0269	0.0275	0.0272
10	0.0289	0.0290	0.0285	0.0291	0.0288
11	0.0314	0.0312	0.0310	0.0311	0.0311
12	0.0345	0.0338	0.0342	0.0340	0.0344
13	0.0370	0.0363	0.0368	0.0370	0.0371
14	0.0400	0.0391	0.0397	0.0401	0.0406
15	0.0421	0.0405	0.0412	0.0417	0.0429
16	0.0434	0.0411	0.0420	0.0424	0.0442
17	0.0415	0.0397	0.0405	0.0412	0.0421
18	0.0381	0.0371	0.0378	0.0382	0.0384
19	0.0339	0.0333	0.0335	0.0333	0.0337
20	0.0305	0.0305	0.0301	0.0304	0.0303
21	0.0288	0.0290	0.0286	0.0289	0.0288
22	0.0267	0.0269	0.0265	0.0271	0.0268
23	0.0239	0.0242	0.0239	0.0244	0.0240
24	0.0217	0.0221	0.0221	0.0222	0.0217

### Lanjutan lampiran 5. MSE, MAPE, Time

Hidden neuron	MSE		MAPE		Time Sec	
	Training	Testing	Training	Testing	Training	Testing
1	6.29E-05	5.45E-05	22.82	24.80	0.0990	0.0130
2	5.84E-05	3.34E-05	20.37	18.76	0.0816	0.0112
3	3.53E-05	5.74E-06	13.49	6.99	0.0945	0.0160
4	3.37E-05	2.55E-06	12.89	4.20	0.0815	0.0121
5	2.66E-05	1.24E-06	11.56	3.37	0.0892	0.0176
6	2.79E-05	8.40E-07	11.72	2.87	0.0881	0.0162
7	2.60E-05	4.74E-07	11.27	2.12	0.0882	0.0157
8	2.63E-05	9.42E-07	11.23	2.29	0.0897	0.0163
9	2.61E-05	5.93E-07	11.16	2.29	0.0845	0.0113
10	2.54E-05	4.86E-07	11.12	1.98	0.0864	0.0159
15	2.49E-05	3.88E-07	11.12	1.81	0.0881	0.0165

### Lampiran 6. MSE, MAPE, Time

Hidden neuron	MSE		MAPE		Time Sec	
	Training	Testing	Training	Testing	Training	Testing
1	3.49E-05	2.52E-05	18.08	18.02	0.0861	0.0119
2	1.80E-05	1.31E-06	11.62	3.85	0.0908	0.0133
3	1.60E-05	1.79E-06	10.82	3.41	0.0828	0.0122
4	1.56E-05	4.90E-07	10.66	2.49	0.0950	0.0148
5	1.53E-05	5.05E-07	10.54	2.49	0.0964	0.0194
6	1.54E-05	5.52E-07	10.69	2.42	0.0891	0.0123
7	1.49E-05	6.32E-07	10.43	2.41	0.0886	0.0167
8	1.51E-05	4.53E-07	10.55	2.26	0.0966	0.0118
9	1.49E-05	4.43E-07	10.41	2.27	0.0907	0.0161
10	1.50E-05	4.17E-07	10.56	2.15	0.0880	0.0162
15	1.48E-05	2.20E-07	10.41	1.65	0.1081	0.0168

Lanjutan lampiran 6. Trial and Error hari Sabtu (\$)

Hasil Trial Prediksi Hari Sabtu, 1 Juli 2017 (\$)						
Jam	Hidden neuron					
	1	2	3	4	5	6
1	0.0244	0.0208	0.0199	0.0205	0.0206	0.0204
2	0.0244	0.0205	0.0192	0.0199	0.0198	0.0195
3	0.0244	0.0203	0.0190	0.0197	0.0195	0.0191
4	0.0244	0.0203	0.0188	0.0194	0.0193	0.0188
5	0.0244	0.0203	0.0188	0.0195	0.0193	0.0187
6	0.0244	0.0203	0.0190	0.0197	0.0196	0.0192
7	0.0244	0.0206	0.0195	0.0203	0.0202	0.0199
8	0.0244	0.0214	0.0215	0.0218	0.0217	0.0220
9	0.0244	0.0227	0.0237	0.0233	0.0233	0.0238
10	0.0244	0.0239	0.0254	0.0247	0.0245	0.0251
11	0.0244	0.0254	0.0267	0.0260	0.0260	0.0263
12	0.0244	0.0266	0.0277	0.0272	0.0272	0.0275
13	0.0244	0.0280	0.0285	0.0286	0.0285	0.0286
14	0.0244	0.0298	0.0292	0.0303	0.0300	0.0299
15	0.0244	0.0307	0.0297	0.0314	0.0311	0.0308
16	0.0244	0.0317	0.0304	0.0329	0.0325	0.0325
17	0.0244	0.0318	0.0303	0.0330	0.0327	0.0324
18	0.0244	0.0313	0.0298	0.0316	0.0313	0.0308
19	0.0244	0.0287	0.0284	0.0284	0.0282	0.0281
20	0.0244	0.0260	0.0269	0.0261	0.0262	0.0264
21	0.0244	0.0247	0.0260	0.0252	0.0252	0.0255
22	0.0244	0.0230	0.0239	0.0234	0.0236	0.0238
23	0.0244	0.0217	0.0213	0.0217	0.0218	0.0219
24	0.0244	0.0214	0.0202	0.0209	0.0210	0.0209

Lanjutan lampiran 6. Trial and Error hari Sabtu (\$)

Hasil Trial Prediksi Hari Sabtu, 1 Juli 2017(\$)					
Jam	Hidden neuron				
	7	8	9	10	15
1	0.0202	0.0205	0.0206	0.0205	0.0204
2	0.0192	0.0196	0.0196	0.0194	0.0193
3	0.0188	0.0192	0.0192	0.0190	0.0188
4	0.0183	0.0188	0.0187	0.0185	0.0182
5	0.0185	0.0188	0.0187	0.0185	0.0182
6	0.0190	0.0193	0.0193	0.0190	0.0188
7	0.0199	0.0200	0.0201	0.0199	0.0198
8	0.0220	0.0219	0.0221	0.0221	0.0220
9	0.0237	0.0236	0.0237	0.0239	0.0236
10	0.0249	0.0248	0.0249	0.0251	0.0248
11	0.0260	0.0261	0.0261	0.0263	0.0260
12	0.0270	0.0272	0.0272	0.0273	0.0272
13	0.0281	0.0284	0.0283	0.0284	0.0286
14	0.0294	0.0297	0.0298	0.0298	0.0305
15	0.0305	0.0308	0.0310	0.0309	0.0317
16	0.0321	0.0325	0.0327	0.0329	0.0336
17	0.0321	0.0328	0.0328	0.0330	0.0337
18	0.0307	0.0310	0.0312	0.0310	0.0318
19	0.0278	0.0279	0.0281	0.0280	0.0283
20	0.0263	0.0263	0.0263	0.0264	0.0262
21	0.0253	0.0253	0.0254	0.0255	0.0252
22	0.0238	0.0238	0.0239	0.0240	0.0237
23	0.0218	0.0219	0.0220	0.0220	0.0218
24	0.0207	0.0210	0.0208	0.0208	0.0207

**Lampiran 7.** Trial and Error hari Minggu (\$)

Hasil Trial Prediksi Hari Minggu, 26 November 2017 (\$)						
Jam	Hidden neuron					
	1	2	3	4	5	6
1	0.0229	0.0215	0.0212	0.0204	0.0206	0.0206
2	0.0230	0.0215	0.0213	0.0206	0.0206	0.0205
3	0.0230	0.0217	0.0213	0.0208	0.0207	0.0204
4	0.0230	0.0218	0.0213	0.0208	0.0207	0.0205
5	0.0229	0.0219	0.0212	0.0207	0.0206	0.0205
6	0.0230	0.0222	0.0217	0.0215	0.0212	0.0210
7	0.0230	0.0222	0.0220	0.0218	0.0216	0.0215
8	0.0230	0.0223	0.0224	0.0223	0.0222	0.0221
9	0.0231	0.0229	0.0235	0.0233	0.0231	0.0231
10	0.0231	0.0231	0.0236	0.0237	0.0237	0.0238
11	0.0230	0.0225	0.0230	0.0231	0.0230	0.0231
12	0.0230	0.0223	0.0228	0.0229	0.0228	0.0229
13	0.0230	0.0217	0.0225	0.0225	0.0223	0.0224
14	0.0230	0.0217	0.0224	0.0224	0.0223	0.0224
15	0.0230	0.0219	0.0223	0.0224	0.0224	0.0225
16	0.0230	0.0218	0.0225	0.0229	0.0229	0.0231
17	0.0231	0.0236	0.0256	0.0270	0.0276	0.0267
18	0.0231	0.0232	0.0267	0.0283	0.0286	0.0270
19	0.0231	0.0236	0.0252	0.0263	0.0269	0.0264
20	0.0231	0.0234	0.0247	0.0247	0.0248	0.0251
21	0.0231	0.0233	0.0236	0.0237	0.0237	0.0237
22	0.0230	0.0225	0.0226	0.0225	0.0224	0.0223
23	0.0230	0.0224	0.0220	0.0219	0.0217	0.0216
24	0.0229	0.0219	0.0212	0.0205	0.0208	0.0210

Lanjutan Lampiran 7. Trial and Error hari Minggu (\$)

Hasil Trial Prediksi Hari Minggu, 26 November 2017(\$)					
Jam	Hidden neuron				
	7	8	9	10	15
1	0.0204	0.0204	0.0205	0.0204	0.0204
2	0.0203	0.0202	0.0204	0.0203	0.0203
3	0.0202	0.0201	0.0203	0.0202	0.0203
4	0.0203	0.0202	0.0202	0.0202	0.0202
5	0.0202	0.0201	0.0201	0.0201	0.0200
6	0.0209	0.0209	0.0208	0.0208	0.0207
7	0.0215	0.0216	0.0214	0.0215	0.0215
8	0.0222	0.0223	0.0221	0.0223	0.0223
9	0.0233	0.0234	0.0234	0.0235	0.0234
10	0.0239	0.0240	0.0240	0.0240	0.0240
11	0.0232	0.0233	0.0233	0.0234	0.0233
12	0.0230	0.0231	0.0230	0.0231	0.0231
13	0.0225	0.0226	0.0225	0.0226	0.0226
14	0.0225	0.0226	0.0225	0.0226	0.0226
15	0.0226	0.0227	0.0225	0.0227	0.0227
16	0.0232	0.0232	0.0232	0.0233	0.0233
17	0.0264	0.0265	0.0261	0.0261	0.0257
18	0.0269	0.0267	0.0266	0.0265	0.0262
19	0.0261	0.0262	0.0259	0.0258	0.0255
20	0.0250	0.0250	0.0251	0.0249	0.0248
21	0.0239	0.0239	0.0240	0.0240	0.0240
22	0.0224	0.0225	0.0223	0.0225	0.0225
23	0.0216	0.0216	0.0214	0.0215	0.0214
24	0.0208	0.0209	0.0205	0.0205	0.0204

# Lanjutan Lampiran 7. MSE, MAPE, Time

Hidden neuron	MSE		MAPE		Time Sec	
	Training	Testing	Training	Testing	Training	Testing
1	4.25E-05	5.97E-06	21.14	7.89	0.0829	0.0127
2	3.46E-05	3.94E-06	16.95	5.01	0.0906	0.0137
3	2.64E-05	1.18E-06	14.54	3.13	0.0869	0.0111
4	2.26E-05	3.81E-07	12.80	2.09	0.0852	0.0132
5	2.04E-05	1.99E-07	11.93	1.58	0.0929	0.0177
6	1.98E-05	5.65E-07	12.04	1.96	0.1066	0.0168
7	1.93E-05	7.02E-07	11.83	2.21	0.0895	0.0155
8	1.93E-05	7.50E-07	12.00	2.31	0.0889	0.0169
9	1.90E-05	8.33E-07	11.75	2.38	0.0865	0.0116
10	1.88E-05	9.21E-07	11.61	2.56	0.0844	0.0135
15	1.84E-05	1.14E-06	11.47	2.78	0.0858	0.0132



### Lampiran 8. Sebagian Data Aktual Hari Senin

Data Harga Aktual Hari Senin					
10/2/2017	10/9/2017	10/16/2017	10/23/2017	10/30/2017	11/6/2017
0.0148	0.0198	0.0180	0.0178	0.0184	0.0195
0.0137	0.0196	0.0179	0.0175	0.0179	0.0193
0.0129	0.0194	0.0179	0.0175	0.0181	0.0195
0.0142	0.0201	0.0181	0.0181	0.0185	0.0200
0.0174	0.0208	0.0187	0.0188	0.0181	0.0217
0.0231	0.0261	0.0223	0.0251	0.0236	0.0287
0.0254	0.0294	0.0309	0.0302	0.0336	0.0327
0.0248	0.0273	0.0291	0.0297	0.0346	0.0305
0.0244	0.0291	0.0284	0.0301	0.0297	0.0325
0.0264	0.0317	0.0286	0.0296	0.0279	0.0329
0.0282	0.0347	0.0295	0.0301	0.0271	0.0330
0.0308	0.0366	0.0289	0.0300	0.0257	0.0332
0.0322	0.0412	0.0288	0.0300	0.0241	0.0327
0.0353	0.0457	0.0284	0.0296	0.0238	0.0310
0.0355	0.0482	0.0279	0.0289	0.0229	0.0301
0.0382	0.0501	0.0279	0.0287	0.0233	0.0302
0.0355	0.0495	0.0276	0.0291	0.0242	0.0350
0.0326	0.0439	0.0283	0.0295	0.0277	0.0387
0.0334	0.0454	0.0347	0.0344	0.0342	0.0343
0.0315	0.0408	0.0305	0.0298	0.0291	0.0302
0.0267	0.0334	0.0268	0.0255	0.0265	0.0269
0.0221	0.0271	0.0228	0.0233	0.0227	0.0251
0.0197	0.0247	0.0204	0.0217	0.0206	0.0227
0.0183	0.0218	0.0183	0.0196	0.0193	0.0219

Lanjutan lampiran 8. Sebagian Data Aktual Hari Senin

Data Harga Aktual Hari Senin					
11/13/2017	11/20/2017	11/27/2017	12/4/2017	12/11/2017	12/18/2017
0.0210	0.0206	0.0209	0.0175	0.0209	0.0199
0.0210	0.0208	0.0207	0.0173	0.0215	0.0200
0.0211	0.0210	0.0208	0.0172	0.0217	0.0197
0.0213	0.0211	0.0210	0.0183	0.0221	0.0200
0.0230	0.0217	0.0241	0.0195	0.0222	0.0208
0.0295	0.0300	0.0285	0.0243	0.0302	0.0224
0.0379	0.0381	0.0324	0.0286	0.0379	0.0292
0.0339	0.0336	0.0287	0.0273	0.0310	0.0268
0.0364	0.0321	0.0275	0.0252	0.0291	0.0261
0.0355	0.0295	0.0264	0.0241	0.0268	0.0261
0.0331	0.0259	0.0252	0.0234	0.0245	0.0247
0.0319	0.0238	0.0245	0.0229	0.0234	0.0237
0.0302	0.0229	0.0230	0.0229	0.0228	0.0232
0.0296	0.0228	0.0229	0.0226	0.0223	0.0229
0.0288	0.0222	0.0224	0.0222	0.0220	0.0224
0.0294	0.0225	0.0228	0.0228	0.0225	0.0226
0.0364	0.0283	0.0275	0.0284	0.0270	0.0278
0.0422	0.0305	0.0290	0.0284	0.0304	0.0282
0.0374	0.0281	0.0273	0.0262	0.0279	0.0257
0.0342	0.0262	0.0248	0.0242	0.0258	0.0242
0.0307	0.0247	0.0229	0.0227	0.0235	0.0225
0.0281	0.0221	0.0221	0.0218	0.0225	0.0214
0.0257	0.0204	0.0205	0.0203	0.0215	0.0198
0.0230	0.0203	0.0183	0.0169	0.0201	0.0187

**Lampiran 9.** Sebagian Data Aktual Hari Selasa

Selasa					
5/23/2017	5/30/2017	6/6/2017	6/13/2017	6/20/2017	6/27/2017
0.0201	0.0198	0.0198	0.0221	0.0197	0.0178
0.0194	0.0188	0.0191	0.0206	0.0189	0.0161
0.0190	0.0181	0.0180	0.0201	0.0180	0.0147
0.0191	0.0180	0.0182	0.0200	0.0178	0.0148
0.0201	0.0198	0.0189	0.0204	0.0186	0.0172
0.0230	0.0223	0.0205	0.0227	0.0197	0.0193
0.0262	0.0245	0.0217	0.0263	0.0208	0.0211
0.0276	0.0257	0.0238	0.0292	0.0233	0.0220
0.0299	0.0267	0.0245	0.0334	0.0240	0.0225
0.0311	0.0274	0.0265	0.0350	0.0263	0.0238
0.0313	0.0272	0.0281	0.0414	0.0278	0.0247
0.0315	0.0275	0.0292	0.0481	0.0291	0.0264
0.0314	0.0266	0.0305	0.0529	0.0312	0.0286
0.0318	0.0275	0.0317	0.0573	0.0337	0.0299
0.0308	0.0270	0.0327	0.0588	0.0353	0.0292
0.0303	0.0262	0.0336	0.0623	0.0365	0.0308
0.0310	0.0263	0.0322	0.0603	0.0361	0.0320
0.0296	0.0256	0.0300	0.0543	0.0344	0.0308
0.0290	0.0248	0.0287	0.0478	0.0318	0.0282
0.0292	0.0256	0.0264	0.0434	0.0290	0.0255
0.0294	0.0296	0.0258	0.0372	0.0278	0.0253
0.0241	0.0250	0.0235	0.0301	0.0253	0.0221
0.0218	0.0220	0.0223	0.0264	0.0233	0.0200
0.0209	0.0213	0.0208	0.0238	0.0210	0.0186

Lanjutan lampiran 9. Sebagian Data Aktual Hari Selasa

Selasa					
7/4/2017	7/11/2017	7/18/2017	7/25/2017	8/1/2017	8/8/2017
0.0191	0.0210	0.0200	0.0194	0.0214	0.0191
0.0180	0.0202	0.0191	0.0177	0.0206	0.0183
0.0172	0.0197	0.0188	0.0172	0.0199	0.0179
0.0165	0.0190	0.0182	0.0170	0.0197	0.0178
0.0164	0.0199	0.0188	0.0181	0.0200	0.0184
0.0166	0.0214	0.0203	0.0198	0.0217	0.0201
0.0180	0.0233	0.0221	0.0217	0.0232	0.0211
0.0202	0.0246	0.0246	0.0232	0.0255	0.0221
0.0222	0.0268	0.0269	0.0246	0.0273	0.0231
0.0243	0.0292	0.0288	0.0270	0.0304	0.0254
0.0247	0.0322	0.0324	0.0289	0.0336	0.0266
0.0259	0.0352	0.0360	0.0318	0.0377	0.0279
0.0284	0.0405	0.0406	0.0346	0.0401	0.0295
0.0305	0.0442	0.0449	0.0378	0.0458	0.0321
0.0320	0.0476	0.0479	0.0413	0.0502	0.0348
0.0338	0.0517	0.0511	0.0464	0.0545	0.0370
0.0353	0.0513	0.0512	0.0472	0.0534	0.0371
0.0335	0.0444	0.0466	0.0409	0.0467	0.0326
0.0299	0.0399	0.0409	0.0353	0.0408	0.0308
0.0275	0.0348	0.0371	0.0317	0.0374	0.0283
0.0268	0.0325	0.0339	0.0310	0.0342	0.0271
0.0236	0.0281	0.0289	0.0256	0.0285	0.0238
0.0221	0.0249	0.0251	0.0244	0.0251	0.0222
0.0209	0.0229	0.0229	0.0225	0.0231	0.0208

### Lampiran 10. Sebagian Data Aktual Hari Rabu

Rabu					
5/24/2017	5/31/2017	6/7/2017	6/14/2017	6/21/2017	6/28/2017
0.0199	0.0201	0.0188	0.0246	0.0199	0.0154
0.0191	0.0191	0.0176	0.0232	0.0189	0.0138
0.0186	0.0185	0.0166	0.0221	0.0176	0.0124
0.0190	0.0182	0.0166	0.0214	0.0172	0.0124
0.0196	0.0201	0.0181	0.0232	0.0186	0.0160
0.0240	0.0212	0.0196	0.0250	0.0193	0.0178
0.0272	0.0240	0.0214	0.0279	0.0213	0.0192
0.0293	0.0248	0.0232	0.0315	0.0227	0.0216
0.0306	0.0250	0.0243	0.0340	0.0240	0.0223
0.0318	0.0271	0.0262	0.0365	0.0262	0.0233
0.0325	0.0275	0.0272	0.0394	0.0288	0.0245
0.0317	0.0290	0.0286	0.0416	0.0315	0.0259
0.0311	0.0300	0.0302	0.0467	0.0335	0.0280
0.0321	0.0311	0.0328	0.0528	0.0372	0.0295
0.0313	0.0306	0.0338	0.0558	0.0390	0.0319
0.0323	0.0300	0.0347	0.0592	0.0408	0.0331
0.0319	0.0304	0.0343	0.0567	0.0411	0.0337
0.0306	0.0292	0.0316	0.0523	0.0384	0.0316
0.0281	0.0288	0.0294	0.0445	0.0355	0.0286
0.0306	0.0297	0.0275	0.0394	0.0322	0.0283
0.0320	0.0317	0.0265	0.0361	0.0305	0.0284
0.0259	0.0261	0.0241	0.0315	0.0268	0.0250
0.0233	0.0233	0.0225	0.0303	0.0252	0.0229
0.0213	0.0201	0.0204	0.0259	0.0224	0.0216

Lanjutan lampiran 10. Sebagian Data Aktual Hari Rabu

Rabu					
7/5/2017	7/12/2017	7/19/2017	7/26/2017	8/2/2017	8/9/2017
0.0196	0.0212	0.0220	0.0203	0.0206	0.0189
0.0190	0.0201	0.0211	0.0187	0.0198	0.0179
0.0184	0.0197	0.0205	0.0179	0.0193	0.0168
0.0181	0.0194	0.0202	0.0175	0.0190	0.0169
0.0188	0.0204	0.0205	0.0189	0.0200	0.0178
0.0200	0.0221	0.0217	0.0202	0.0217	0.0193
0.0216	0.0234	0.0233	0.0217	0.0229	0.0197
0.0241	0.0255	0.0272	0.0237	0.0246	0.0217
0.0253	0.0281	0.0301	0.0251	0.0264	0.0224
0.0277	0.0315	0.0340	0.0274	0.0295	0.0247
0.0298	0.0349	0.0386	0.0305	0.0317	0.0272
0.0328	0.0393	0.0433	0.0338	0.0337	0.0275
0.0365	0.0449	0.0484	0.0376	0.0376	0.0303
0.0402	0.0498	0.0527	0.0424	0.0423	0.0330
0.0424	0.0533	0.0557	0.0460	0.0450	0.0355
0.0470	0.0574	0.0598	0.0512	0.0485	0.0368
0.0470	0.0576	0.0597	0.0521	0.0466	0.0365
0.0417	0.0532	0.0544	0.0453	0.0394	0.0324
0.0367	0.0472	0.0483	0.0407	0.0360	0.0298
0.0325	0.0412	0.0438	0.0358	0.0324	0.0273
0.0306	0.0369	0.0392	0.0337	0.0308	0.0261
0.0267	0.0317	0.0324	0.0285	0.0264	0.0231
0.0241	0.0240	0.0281	0.0255	0.0240	0.0218
0.0222	0.0220	0.0245	0.0241	0.0218	0.0203

**Lampiran 11.** Sebagian Data Aktual Hari Kamis

Kamis					
4/13/2017	4/20/2017	4/27/2017	5/4/2017	5/11/2017	5/18/2017
0.0203	0.0211	0.0200	0.0206	0.0237	0.0216
0.0202	0.0205	0.0194	0.0202	0.0227	0.0200
0.0201	0.0196	0.0190	0.0199	0.0223	0.0193
0.0203	0.0201	0.0198	0.0200	0.0224	0.0199
0.0216	0.0217	0.0209	0.0213	0.0263	0.0214
0.0263	0.0263	0.0254	0.0285	0.0317	0.0262
0.0315	0.0301	0.0303	0.0328	0.0344	0.0294
0.0304	0.0296	0.0303	0.0326	0.0352	0.0303
0.0307	0.0318	0.0303	0.0330	0.0337	0.0322
0.0320	0.0347	0.0313	0.0334	0.0364	0.0348
0.0326	0.0357	0.0314	0.0333	0.0366	0.0374
0.0322	0.0359	0.0318	0.0322	0.0379	0.0387
0.0310	0.0374	0.0323	0.0323	0.0380	0.0429
0.0307	0.0369	0.0314	0.0321	0.0411	0.0466
0.0297	0.0353	0.0310	0.0302	0.0413	0.0485
0.0295	0.0349	0.0305	0.0302	0.0402	0.0522
0.0297	0.0352	0.0310	0.0305	0.0396	0.0510
0.0294	0.0337	0.0308	0.0293	0.0360	0.0458
0.0289	0.0322	0.0294	0.0271	0.0335	0.0396
0.0333	0.0365	0.0358	0.0316	0.0377	0.0389
0.0303	0.0346	0.0364	0.0326	0.0362	0.0371
0.0247	0.0272	0.0279	0.0249	0.0310	0.0301
0.0220	0.0239	0.0255	0.0224	0.0258	0.0265
0.0205	0.0225	0.0226	0.0203	0.0226	0.0229

Lanjutan Lampiran 11. Sebagian Data Aktual Hari Kamis

Kamis					
5/25/2017	6/1/2017	6/8/2017	6/15/2017	6/22/2017	6/29/2017
0.0198	0.0211	0.0194	0.0217	0.0200	0.0189
0.0189	0.0193	0.0182	0.0206	0.0189	0.0175
0.0182	0.0191	0.0176	0.0199	0.0181	0.0170
0.0185	0.0192	0.0178	0.0196	0.0183	0.0170
0.0200	0.0214	0.0185	0.0203	0.0191	0.0183
0.0231	0.0239	0.0203	0.0216	0.0213	0.0198
0.0258	0.0268	0.0221	0.0241	0.0232	0.0209
0.0277	0.0267	0.0240	0.0263	0.0249	0.0228
0.0270	0.0276	0.0253	0.0290	0.0263	0.0247
0.0286	0.0300	0.0276	0.0308	0.0270	0.0268
0.0278	0.0311	0.0294	0.0344	0.0293	0.0286
0.0283	0.0334	0.0317	0.0365	0.0334	0.0321
0.0303	0.0368	0.0333	0.0413	0.0354	0.0356
0.0305	0.0368	0.0366	0.0459	0.0388	0.0391
0.0311	0.0392	0.0380	0.0499	0.0422	0.0415
0.0302	0.0392	0.0396	0.0532	0.0440	0.0437
0.0298	0.0369	0.0386	0.0516	0.0424	0.0432
0.0291	0.0341	0.0371	0.0479	0.0395	0.0405
0.0278	0.0330	0.0337	0.0421	0.0361	0.0353
0.0294	0.0307	0.0313	0.0364	0.0329	0.0319
0.0294	0.0331	0.0308	0.0349	0.0305	0.0305
0.0262	0.0273	0.0272	0.0314	0.0268	0.0264
0.0240	0.0248	0.0240	0.0297	0.0246	0.0242
0.0218	0.0221	0.0216	0.0253	0.0228	0.0224



**Lampiran 12.** Sebagian Data Aktual Hari Jumat

Jumat					
4/14/2017	4/21/2017	4/28/2017	5/5/2017	5/12/2017	5/19/2017
0.0187	0.0208	0.0218	0.0212	0.0220	0.0210
0.0185	0.0201	0.0212	0.0204	0.0216	0.0197
0.0181	0.0201	0.0208	0.0199	0.0210	0.0189
0.0184	0.0204	0.0211	0.0204	0.0216	0.0194
0.0189	0.0215	0.0226	0.0222	0.0256	0.0217
0.0222	0.0258	0.0271	0.0257	0.0311	0.0267
0.0250	0.0288	0.0323	0.0305	0.0346	0.0313
0.0251	0.0297	0.0330	0.0321	0.0358	0.0318
0.0260	0.0305	0.0329	0.0327	0.0350	0.0331
0.0275	0.0325	0.0353	0.0323	0.0371	0.0333
0.0279	0.0318	0.0362	0.0314	0.0369	0.0332
0.0279	0.0320	0.0365	0.0304	0.0371	0.0346
0.0285	0.0327	0.0372	0.0300	0.0383	0.0380
0.0289	0.0328	0.0366	0.0295	0.0388	0.0397
0.0292	0.0312	0.0355	0.0295	0.0368	0.0391
0.0300	0.0300	0.0368	0.0282	0.0368	0.0386
0.0304	0.0281	0.0340	0.0276	0.0350	0.0373
0.0284	0.0261	0.0312	0.0266	0.0322	0.0334
0.0267	0.0263	0.0288	0.0261	0.0301	0.0315
0.0296	0.0283	0.0349	0.0284	0.0335	0.0326
0.0285	0.0276	0.0355	0.0286	0.0313	0.0311
0.0234	0.0221	0.0273	0.0232	0.0263	0.0262
0.0224	0.0218	0.0253	0.0239	0.0253	0.0245
0.0205	0.0209	0.0230	0.0227	0.0221	0.0225

Lanjutan lampiran 12. Sebagian Data Aktual Hari Jumat

Jumat					
5/26/2017	6/2/2017	6/9/2017	6/16/2017	6/23/2017	6/30/2017
0.0183	0.0202	0.0193	0.0212	0.0208	0.0207
0.0172	0.0174	0.0183	0.0204	0.0203	0.0199
0.0163	0.0171	0.0176	0.0192	0.0192	0.0196
0.0169	0.0176	0.0177	0.0190	0.0191	0.0196
0.0184	0.0199	0.0183	0.0194	0.0199	0.0201
0.0216	0.0235	0.0202	0.0210	0.0212	0.0215
0.0246	0.0255	0.0218	0.0246	0.0231	0.0234
0.0254	0.0267	0.0239	0.0261	0.0247	0.0252
0.0281	0.0284	0.0270	0.0286	0.0262	0.0274
0.0296	0.0302	0.0293	0.0313	0.0277	0.0285
0.0311	0.0329	0.0309	0.0350	0.0300	0.0301
0.0320	0.0344	0.0331	0.0405	0.0331	0.0336
0.0351	0.0380	0.0362	0.0428	0.0358	0.0362
0.0373	0.0415	0.0405	0.0479	0.0384	0.0401
0.0360	0.0441	0.0407	0.0514	0.0395	0.0418
0.0371	0.0436	0.0440	0.0547	0.0400	0.0442
0.0354	0.0437	0.0413	0.0514	0.0378	0.0417
0.0322	0.0396	0.0380	0.0464	0.0357	0.0373
0.0309	0.0344	0.0331	0.0411	0.0319	0.0338
0.0299	0.0318	0.0306	0.0345	0.0291	0.0299
0.0300	0.0316	0.0287	0.0319	0.0274	0.0284
0.0273	0.0280	0.0262	0.0290	0.0256	0.0256
0.0254	0.0251	0.0244	0.0270	0.0227	0.0239
0.0222	0.0228	0.0219	0.0237	0.0208	0.0217

### Lampiran 13. Sebagian Data Aktual Hari Sabtu

Sabtu					
4/15/2017	4/22/2017	4/29/2017	5/6/2017	5/13/2017	5/20/2017
0.0180	0.0202	0.0211	0.0214	0.0196	0.0193
0.0175	0.0205	0.0203	0.0207	0.0199	0.0177
0.0174	0.0201	0.0198	0.0201	0.0191	0.0166
0.0174	0.0203	0.0199	0.0204	0.0188	0.0165
0.0178	0.0207	0.0203	0.0207	0.0201	0.0174
0.0189	0.0219	0.0213	0.0214	0.0212	0.0197
0.0200	0.0233	0.0228	0.0235	0.0224	0.0218
0.0221	0.0255	0.0245	0.0252	0.0245	0.0249
0.0238	0.0292	0.0285	0.0288	0.0270	0.0276
0.0259	0.0300	0.0302	0.0295	0.0295	0.0295
0.0261	0.0304	0.0306	0.0296	0.0302	0.0302
0.0262	0.0299	0.0298	0.0276	0.0292	0.0309
0.0261	0.0273	0.0294	0.0266	0.0287	0.0319
0.0258	0.0270	0.0299	0.0254	0.0286	0.0328
0.0261	0.0262	0.0299	0.0248	0.0288	0.0334
0.0266	0.0265	0.0299	0.0243	0.0288	0.0345
0.0279	0.0271	0.0298	0.0245	0.0304	0.0344
0.0275	0.0270	0.0296	0.0245	0.0273	0.0331
0.0256	0.0278	0.0268	0.0249	0.0260	0.0318
0.0295	0.0317	0.0305	0.0297	0.0267	0.0312
0.0287	0.0317	0.0310	0.0292	0.0283	0.0310
0.0226	0.0244	0.0228	0.0232	0.0241	0.0263
0.0209	0.0226	0.0217	0.0211	0.0231	0.0240
0.0187	0.0218	0.0197	0.0204	0.0214	0.0222

Lanjutan lampiran 13. Sebagian Data Aktual Hari Sabtu

Sabtu					
5/27/2017	6/3/2017	6/10/2017	6/17/2017	6/24/2017	7/1/2017
0.0204	0.0219	0.0194	0.0213	0.0187	0.0201
0.0193	0.0204	0.0178	0.0203	0.0177	0.0191
0.0195	0.0195	0.0168	0.0194	0.0173	0.0187
0.0187	0.0191	0.0166	0.0189	0.0167	0.0181
0.0187	0.0199	0.0170	0.0188	0.0173	0.0179
0.0194	0.0204	0.0176	0.0189	0.0180	0.0184
0.0209	0.0226	0.0193	0.0200	0.0189	0.0192
0.0227	0.0255	0.0227	0.0225	0.0216	0.0212
0.0241	0.0275	0.0252	0.0252	0.0230	0.0231
0.0267	0.0297	0.0269	0.0274	0.0248	0.0243
0.0278	0.0318	0.0293	0.0303	0.0253	0.0257
0.0292	0.0338	0.0308	0.0320	0.0263	0.0269
0.0306	0.0361	0.0331	0.0346	0.0276	0.0281
0.0303	0.0388	0.0377	0.0388	0.0286	0.0293
0.0305	0.0407	0.0409	0.0420	0.0288	0.0305
0.0314	0.0425	0.0453	0.0461	0.0297	0.0327
0.0317	0.0442	0.0467	0.0472	0.0303	0.0326
0.0301	0.0411	0.0440	0.0431	0.0282	0.0304
0.0290	0.0359	0.0368	0.0362	0.0264	0.0270
0.0275	0.0318	0.0313	0.0324	0.0248	0.0256
0.0281	0.0331	0.0290	0.0302	0.0247	0.0246
0.0245	0.0287	0.0261	0.0271	0.0224	0.0233
0.0225	0.0247	0.0232	0.0254	0.0205	0.0212
0.0203	0.0228	0.0222	0.0232	0.0194	0.0199

**Lampiran 14.** Sebagian Data Aktual Hari Minggu

Minggu					
9/10/2017	9/17/2017	9/24/2017	10/1/2017	10/8/2017	10/15/2017
0.0170	0.0192	0.0200	0.0143	0.0193	0.0172
0.0157	0.0185	0.0191	0.0137	0.0188	0.0174
0.0141	0.0180	0.0187	0.0134	0.0184	0.0174
0.0138	0.0174	0.0181	0.0128	0.0182	0.0167
0.0144	0.0175	0.0183	0.0136	0.0181	0.0162
0.0167	0.0187	0.0188	0.0149	0.0192	0.0167
0.0173	0.0194	0.0199	0.0164	0.0194	0.0173
0.0182	0.0208	0.0211	0.0177	0.0203	0.0190
0.0207	0.0238	0.0253	0.0199	0.0236	0.0210
0.0218	0.0248	0.0273	0.0208	0.0240	0.0219
0.0224	0.0272	0.0319	0.0214	0.0254	0.0229
0.0225	0.0289	0.0426	0.0216	0.0261	0.0236
0.0237	0.0333	0.0475	0.0220	0.0282	0.0238
0.0245	0.0358	0.0592	0.0222	0.0314	0.0232
0.0252	0.0401	0.0648	0.0226	0.0318	0.0229
0.0274	0.0453	0.0734	0.0234	0.0346	0.0232
0.0281	0.0461	0.0697	0.0248	0.0379	0.0245
0.0265	0.0413	0.0537	0.0258	0.0387	0.0275
0.0258	0.0364	0.0440	0.0280	0.0414	0.0338
0.0273	0.0358	0.0421	0.0283	0.0364	0.0309
0.0248	0.0292	0.0369	0.0244	0.0306	0.0258
0.0211	0.0249	0.0282	0.0206	0.0249	0.0218
0.0193	0.0219	0.0242	0.0187	0.0235	0.0208
0.0185	0.0204	0.0211	0.0174	0.0209	0.0189

Lanjutan lampiran 14. Sebagian Data Aktual Hari Minggu

Minggu					
10/22/2017	10/29/2017	11/5/2017	11/12/2017	11/19/2017	11/26/2017
0.0188	0.0213	0.0190	0.0236	0.0198	0.0207
0.0185	0.0213	0.0183	0.0238	0.0197	0.0205
0.0181	0.0212	0.0178	0.0235	0.0198	0.0203
0.0178	0.0209	0.0178	0.0229	0.0201	0.0204
0.0177	0.0210	0.0178	0.0222	0.0200	0.0201
0.0185	0.0219	0.0187	0.0236	0.0217	0.0208
0.0189	0.0243	0.0201	0.0249	0.0225	0.0218
0.0206	0.0261	0.0212	0.0264	0.0237	0.0224
0.0221	0.0289	0.0219	0.0289	0.0258	0.0232
0.0235	0.0286	0.0232	0.0293	0.0267	0.0238
0.0242	0.0268	0.0229	0.0287	0.0252	0.0227
0.0248	0.0259	0.0228	0.0285	0.0246	0.0223
0.0253	0.0242	0.0226	0.0287	0.0234	0.0220
0.0258	0.0228	0.0227	0.0283	0.0233	0.0218
0.0249	0.0223	0.0230	0.0276	0.0236	0.0217
0.0257	0.0225	0.0244	0.0289	0.0242	0.0226
0.0267	0.0233	0.0302	0.0359	0.0329	0.0277
0.0280	0.0278	0.0332	0.0402	0.0349	0.0297
0.0344	0.0370	0.0286	0.0343	0.0316	0.0279
0.0293	0.0308	0.0248	0.0323	0.0288	0.0252
0.0256	0.0269	0.0226	0.0286	0.0270	0.0231
0.0221	0.0226	0.0213	0.0267	0.0242	0.0227
0.0213	0.0210	0.0198	0.0244	0.0229	0.0215
0.0195	0.0194	0.0197	0.0219	0.0209	0.0211

## RIWAYAT HIDUP



Penulis bernama lengkap Akhmad Rizki Hidayatullah, merupakan anak kedua dari dua bersaudara. Dilahirkan pada 20 September 1995 di Kota Surabaya oleh pasangan dr. Achmad Ekaprasetyana dengan Dr. Sri Umijati, dr., MS. Mengawali pendidikan di SD Muhammadiyah 16, Surabaya sampai dengan 2008 kemudian penulis melanjutkan pendidikan menengahnya di SMP Negeri 1 Surabaya sampai dengan 2011 dan melanjutkan pendidikan menengah atasnya di SMA Negeri 5 Surabaya hingga lulus pada tahun 2014. Sejak tahun 2014 penulis terdaftar sebagai Mahasiswa Teknik Elektro, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember, bidang studi Teknik Sistem Tenaga, melalui jalur suci yaitu Seleksi Bersama Masuk Perguruan Tinggi Negeri (SBMPTN) 2014. Selama menempuh pendidikan di ITS, penulis aktif di keorganisasian ITS yaitu BEM ITS dan aktif sebagai asisten Laboratorium Simulasi Sistem Tenaga Listrik (PSSL) sebagai koordinator asisten. Berbagai kepanitiaan juga diikuti penulis hingga penulis pernah menjadi ketua di event terbesar ITS yaitu Generasi Integralistik ITS (GERIGI) 2015. Penulis juga aktif dalam kegiatan penelitian dan pengabdian masyarakat. Penulis dapat dihubungi melalui email [rizkihidayatullah@gmail.com](mailto:rizkihidayatullah@gmail.com).

*Halaman ini sengaja dikosongkan*